

# **CONTRIBUȚII LA DIAGNOSTICUL ASISTAT DE CALCULATOR ÎN IMAGINILE DE ULTRASONOGRAFIE ABDOMINALĂ**

Teză destinată obținerii  
titlului științific de doctor inginer  
la  
Universitatea *Politehnica* Timișoara  
în domeniul INGINERIE ELECTRONICĂ ȘI  
TELECOMUNICAȚII  
de către

**Ing. Dan Mihai Mihăilescu**

Conducător științific: prof.univ.dr.ing. Corneliu Ioan Toma  
Referenți științifici: prof.univ.dr.ing. Gavril Todorean  
prof.univ.dr. Ioan Sporea  
prof.univ.dr.ing. Vasile Gui

Ziua susținerii tezei: 28 februarie 2014

Seriile Teze de doctorat ale UPT sunt:

- |   |  |
|---|--|
| 1. Automatică                               | 9. Inginerie Mecanică                      |
| 2. Chimie                                   | 10. Știința Calculatoarelor                |
| 3. Energetică                               | 11. Știința și Ingineria Materialelor      |
| 4. Ingineria Chimică                        | 12. Ingineria sistemelor                   |
| 5. Inginerie Civilă                         | 13. Inginerie energetică                   |
| 6. Inginerie Electrică                      | 14. Calculatoare și tehnologia informației |
| 7. Inginerie Electronică și Telecomunicații | 15. Ingineria materialelor                 |
| 8. Inginerie Industrială                    | 16. Inginerie și Management                |

Universitatea *Politehnica* Timișoara a inițiat seriile de mai sus în scopul diseminării expertizei, cunoștințelor și rezultatelor cercetărilor întreprinse în cadrul școlii doctorale a universității. Seriile conțin, potrivit H.B.Ex.S Nr. 14 / 14.07.2006, tezele de doctorat susținute în universitate începând cu 1 octombrie 2006.

Copyright © Editura Politehnica – Timișoara, 2014

Această publicație este supusă prevederilor legii dreptului de autor. Multiplicarea acestei publicații, în mod integral sau în parte, traducerea, tipărirea, reutilizarea ilustrațiilor, expunerea, radiodifuzarea, reproducerea pe microfilme sau în orice altă formă este permisă numai cu respectarea prevederilor Legii române a dreptului de autor în vigoare și permisiunea pentru utilizare obținută în scris din partea Universității *Politehnica* Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300159 Timișoara, Bd. Republicii 9,  
tel. 0256 403823, fax. 0256 403221  
e-mail: editura@edipol.upt.ro

## Cuvânt înainte

Teza de doctorat a fost elaborată pe parcursul activității mele în cadrul Departamentului de Comunicații al Universității *Politehnica* Timișoara. Aceasta constituie rezultatul unui efort depus pe parcursul a trei ani și jumătate de studiu.

Lucrarea este rezultatul unei colaborări între Universitatea *Politehnica* Timișoara și Universitatea de Medicină și Farmacie „Victor Babeș” din Timișoara, Departamentul de Medicină Internă II, Disciplina de Gastroenterologie.

Teza de doctorat propune soluții originale în analiza imaginilor medicale ultrasonografice cu aplicații în diagnosticarea automată a steatozei și extragerea curbei de intensități în domeniul timp pentru analiza leziunii hepatice focale în ultrasonografia cu substanță de contrast.

Doresc să-mi exprim gratitudinea pentru lecțiile de anatomie a ficatului și stabilirea de diagnostice folosind ultrasonografia standard și ultrasonografia cu substanță de contrast și pentru imaginile și secvențele video, pentru munca depusă în colectarea bazei de date și punerea acesteia la dispoziția noastră de către prof. univ. dr. Ioan Sporea.

Aduc mulțumiri deosebite conducătorului științific al tezei prof. univ. dr. ing. Corneliu Ioan Toma pentru sprijinul și îndrumarea constantă realizată cu foarte multă delicatețe și care m-a încurajat mereu în momentele dificile ce au apărut pe parcursul realizării ei.

Mulțumiri speciale domnului prof. univ. dr. ing. Vasile Gui pentru consecvența cu care a urmărit finalizarea prezentei teze.

Timișoara, februarie 2014

Dan Mihai Mihăilescu

“This work was partially supported by the strategic grant POSDRU 107/1.5/S/77265 (2010) of the Ministry of Labor, Family and Social Protection, Romania, co-financed by the European Social Fund – Investing in people.”

Mihăilescu, Dan Mihai

**Contribuții la diagnosticul asistat de calculator în imaginile de ultrasonografie abdominală**

Teze de doctorat ale UPT, Seria 7, Nr. 68, Editura Politehnica, 2014, 90 pagini, 25 figuri, 10 tabele.

ISSN: 1842-7014

ISBN: 978-606-554-790-2

**Cuvinte cheie:** diagnostic asistat de calculator, ultrasonografie abdominală, analiza imaginilor medicale, steatoză, leziuni hepatice focale, substanță de contrast

**Rezumat:**

Teza de doctorat își propune găsirea de soluții originale în analiza imaginilor medicale ultrasonografice, cu aplicații, în diagnosticarea automată a steatozei și extragerea curbei de intensități în domeniul timp pentru analiza leziunii hepatice focale în CEUS. Pentru diagnosticarea automată a steatozei se selectează o regiune de interes. Folosind tehnica de regresie robustă având ca idee de pornire algoritmul RANSAC, se obține o regresie a profilului intensității mai puțin sensibilă la zgomot și valori extreme din regiunea de interes selectată. Am realizat extragerea mai multor parametri utili pentru clasificarea steatozei din imagini ultrasonografice standard reprezentând ficatul. Parametrii obținuți sunt utilizați la generarea vectorilor de caracteristici în clasificare. S-a realizat o clasificare automată a steatozei din imagini ultrasonografice folosind clasificatorul Random Forests. Cele mai bune clasificatoare în domeniul procesării imaginilor la ora actuală, Random Forests și SVM ne-au ajutat să comparăm rezultatele clasificării gradului de severitate a steatozei hepatice. Datorită zgomotului speckle de tip multiplicativ și a mișcării leziunii hepatice din secvența video ultrasonografică CEUS, curba de intensități în domeniul timp prezintă variații mari în amplitudine. Am propus o metodă nouă pentru extragerea curbei de intensități în domeniul timp din secvențe video.

Studiile noastre prezintă un interes atât pentru inginerie cât și pentru medicină. Pentru inginerie am propus metode noi pentru clasificarea automată folosind imagini ultrasonografice, iar în medicină un ajutor în diagnosticarea pacienților.



## CUPRINS

CUPRINS .....	5
LISTĂ DE TABELE .....	6
LISTĂ DE FIGURI .....	7
1. INTRODUCERE .....	8
1.1. Motivație.....	8
1.2. Obiectivele tezei.....	9
1.3. Structura tezei.....	9
1.4. Lucrări publicate sau prezentate de doctorand .....	11
2. IMAGINI BIOMEDICALE .....	12
2.1. Considerații generale privind prelucrarea imaginilor biomedicale .....	12
2.2. Ultrasonografia și imagini ultrasonografice .....	12
2.3. Ultrasonografia abdominală .....	14
2.4. Imagini ultrasonografice.....	15
2.4.1. Zgomotul în imagini.....	15
2.4.2. Concluzii .....	16
3. TEHNICI DE ESTIMAȚIE ROBUSTĂ ÎN VEDEREA ARTIFICIALĂ.....	17
3.1. Estimatorii L .....	18
3.2. Estimatorul LMedS .....	18
3.3. Estimatorii M .....	19
3.4. Transformarea Hough .....	21
3.5. Algoritmul RANSAC.....	24
3.6. Algoritmul MSAC .....	26
3.7. Algoritmul MLESAC .....	27
3.8. Algoritmul NAPSAC .....	28
3.9. Algoritmul Mean Shift .....	29
4. EVALUAREA ASISTATĂ DE CALCULATOR A IMAGINILOR ULTRASONOGRAFICE CU STEATOZĂ .....	34
4.1. Considerații generale .....	34
4.2. Stadiu actual .....	35
4.3. Evaluarea automată a steatozei folosind parametrii extrași cu metode de estimație robuste și clasificatoare Random Forests .....	36
4.3.1. Caracterizarea atenuării posterioare folosind două pante .....	37
4.3.2. Clasificare.....	42
4.3.3. Rezultate experimentale.....	50
4.4. Studiu comparativ folosind două clasificatoare, Random Forests și SVM .	51
4.4.1. Experimente .....	52
5. EXTRAGEREA OPTIMIZATĂ A CURBELOR INTENSITATE-TIMP ÎN ULTRASONOGRAFIA DE CONTRAST .....	57
5.1. Motivație teoretică.....	65
5.2. Utilizarea mean shift în tracking-ul leziunilor hepatice focale și extragerea curbelor intensitate-timp din CEUS .....	66
5.3. Rezultate experimentale.....	70
6. CONCLUZII GENERALE ȘI CONTRIBUȚII .....	80
6.1. Contribuții teoretice.....	80
6.2. Contribuții aplicative.....	81
BIBLIOGRAFIE .....	82

## LISTĂ DE TABELE

Tabel 1 Matricea de confuzie pentru clasificatorul Random Forests cu întregul set de date [39].....	50
Tabel 2 Matricea de confuzie pentru clasificatorul Random Forests cu dihotomii succesive [39].....	50
Tabel 3 Importanța parametrilor utilizați în clasificare folosind cele două variante pentru clasificatorul Random Forests [39].....	51
Tabel 4 Clasificare cu Support Vector Machines cu dihotomii [45].....	53
Tabel 5 Clasificare cu Random Forests cu dihotomii [45].....	53
Tabel 6 Importanța variabilelor utilizate în clasificare [45] .....	54
Tabel 7 Clasificare cu SVM și dihotomii succesive folosind setul de caracteristici ce include maximul robust din regiunea de interes hepatică și mediana nivelurilor de gri din regiunea de interes a ficatului [45] .....	54
Tabel 8 Clasificare cu Random Forests și dihotomii succesive folosind setul de caracteristici ce include maximul robust din regiunea de interes hepatică și mediana nivelurilor de gri din regiunea de interes a ficatului [45] .....	55
Tabel 9 Parametrii clasificării cu SVM și dihotomii succesive considerând setul de caracteristici ce include atenuarea posterioară minimă generată cu o metodă robustă și mediana nivelurilor de gri a regiunii de interes a ficatului [45] .....	55
Tabel 10 Parametrii clasificării cu Random Forests și dihotomii succesive considerând setul de caracteristici ce include atenuarea posterioară minimă generată cu o metodă robustă și mediana nivelurilor de gri a regiunii de interes a ficatului [45] .....	56

## LISTĂ DE FIGURI

Fig. 3.1 Transformarea Hough pentru detecția liniilor drepte .....	22
Fig. 3.2 Reprezentarea dreptei prin ecuația normală.....	23
Fig. 4.1 Selecție interactivă a regiunii de interes .....	38
Fig. 4.2 Profil generat automat din zona selectată .....	39
Fig. 4.3 Regresie robustă .....	41
Fig. 4.4 Selecție în timp real a RI în rinichi (dreptunghi roșu) și RI din ficat (dreptunghi verde).....	42
Fig. 4.5 Grade de severitate pentru steatoză în ficat.....	43
Fig. 4.6 Stadii de severitate pentru steatoză: (a) ficat normal, (b) steatoză ușoară, (c) steatoză moderată, (d) steatoză severă.....	47
Fig. 4.7 Clasificarea steatozei pe bază de dihotomii succesive.....	49
Fig. 5.1 Carcinom hepatocelular.....	58
Fig. 5.2 Hemangiom.....	59
Fig. 5.3 Hiperplazie nodulară focală.....	60
Fig. 5.4 Metastaze hepatice.....	61
Fig. 5.5 Model teoretic pentru TIC. $I(t)$ reprezintă intensitatea în RI .....	62
Fig. 5.6 Selecție interactivă RI la cadrul 245 din secvența CEUS .....	67
Fig. 5.7 Model teoretic al profilului kernelului.....	69
Fig. 5.8 Generarea curbei intensitate-timp folosind mediile intensităților [46] .....	71
Fig. 5.9 Generare curba intensitate-timp folosind medianele intensităților [46] ....	72
Fig. 5.10 Deplasarea leziunii hepatice în secvența video CEUS, cadrul 310 .....	73
Fig. 5.11 Deplasarea leziunii hepatice în secvența video CEUS, cadrul 328 .....	74
Fig. 5.12 Deplasarea leziunii hepatice în secvența video CEUS, cadrul 340 .....	75
Fig. 5.13 Deplasarea leziunii hepatice în secvența video CEUS, cadrul 350 .....	76
Fig. 5.14 Deplasarea leziunii hepatice în secvența video CEUS, cadrul 362 .....	77
Fig. 5.15 Estimarea curbei intensitate-timp cu algoritmul mean shift [46] .....	78
Fig. 5.16 Urmărirea leziunii hepatice cu tracker-ul mean shift [46].....	79



# 1. INTRODUCERE

În ultimul timp imagistica medicală, datorită dezvoltării metodelor de captare digitală a imaginilor, este tot mai prezentă în stabilirea unui diagnostic și implicit a unui tratament medical, fără a apela la o metoda invazivă asupra corpului uman, dacă aceasta nu este necesară. În medicină există mai multe modalități de achiziție a imaginilor medicale cum sunt ultrasonografia (Ultrasound, US), radiografia ( X-ray imaging), rezonanța magnetică (Magnetic Resonance Imaging, MRI), tomografia cu ajutorul calculatorului (Computer tomography, CT) și altele. Ultrasonografia este larg răspândită la nivel mondial. Aceasta are la bază dezvoltarea tehnologiei sonarelor. Imaginile ultrasonografice au un rol important în medicină la evaluarea organelor interne ale organismului și în obstetrică la evaluarea sarcinii. Ficatul este un organ intern important al organismului. Ultrasonografia este o metodă de investigație imagistică eficientă pentru evaluarea posibilelor patologii ale ficatului precum și la identificarea și diagnosticarea leziunilor hepatice focale.

Ultrasonografia se bazează pe semnalul reflectat de țesutul aparținător organului intern. În funcție de tipul țesutului ultrasunetele sunt mai mult sau mai puțin reflectate către sursa care le-a emis. În cazul ficatului se pot depista maladii cum sunt steatoza hepatică, ciroza, fibroza hepatică, precum și tipuri de leziuni hepatice focale, ca de exemplu carcinoame hepatocelulare (HCC), hiperplazii nodulare focale (FNH), metastaze hipervasculare, hemangioame, abces hepatic. Procesarea imaginilor medicale este un domeniu de mare interes ce ajută la evaluarea medicală a maladiilor.

## 1.1. Motivație

Deoarece ultrasonografia este tot mai des utilizată în medicină, diagnosticul bazat pe aceasta metodă este necesar a fi cât mai precis. În ultimii ani în domeniul medical se vorbește tot mai mult de ultrasonografia cu substanță de contrast (CEUS). Steatoza și leziunile focale sunt maladii ale ficatului din ce în ce mai frecvente. Evaluarea acestora folosind ultrasonografia este importantă. Studiul nostru oferă o sursă de informație complementară pentru diagnosticarea steatozei hepatice și propune noi caracteristici în procesul de evaluare automată. Steatoza hepatică este o maladie tot mai des întâlnită și se manifestă prin acumularea de grăsimi în ficat. Relativ recent, utilizarea substanței de contrast în ultrasonografie a făcut posibilă evaluarea medicală a unui spectru mai larg de maladii ale ficatului. Astfel, se pot monitoriza leziuni hepatice maligne și benigne din ficat. Procesarea secvențelor video CEUS are o importanță din ce în ce mai semnificativă în diagnosticarea cu ajutorul calculatorului a tipurilor de leziuni hepatice. Generarea curbilor intensitate-timp din CEUS are un rol important în etapa de clasificare a imaginilor. Evaluarea automată a maladiilor hepatice prin programe performante de calculator este utilă în procesul de diagnosticare și tratament.

## 1.2. Obiectivele tezei

Folosirea imaginilor medicale ultrasonografice ca element definitoriu pentru clasificarea automată a steatozei hepatice alături de extragerea curbelor intensitate-timp folosind o metodă robustă din secvențe video obținute prin noi tehnologii folosind substanța de contrast în ultrasonografie reprezintă principalele obiective ale prezentei teze. În scopul de a determina în ce măsură premisele teoretice ale utilității studiului imagisticii medicale sunt atinse, este necesară proiectarea unui sistem care să realizeze premisele teoretice. Acest sistem folosește elemente existente din cadrul procesării imaginilor medicale, iar noi propunem un model automat (procesare utilizând programe de calculator). Obiectivele tezei au o finalitate atât în inginerie cât și în medicină. Dezvoltarea metodelor tehnico-științifice au la bază obiectivele medicale și anume stabilirea unui diagnostic corect. Aceste obiective sunt atinse prin:

- Ultrasonografia standard
- Ultrasonografia cu substanță de contrast

În lucrarea de față vorbim despre ultrasonografie ca metodă folosită în a identifica steatoza hepatică și leziunile hepatice focale.

În comparație cu tomografia cu ajutorul calculatorului, radiologia și imagistica folosind rezonanța magnetică, această metodă este mai accesibilă populației având costuri reduse.

Un avantaj semnificativ al ultrasonografiei îl reprezintă faptul că este non-invazivă, motiv pentru care poate fi aplicată pacienților ori de câte ori este necesar. Datorită caracteristicii non-invazive aceasta nu are reacții adverse ale organismului uman.

## 1.3. Structura tezei

În capitolul 1 „**Introducere**” se prezintă motivația și obiectivele tezei. Se face o scurtă prezentare a ultrasonografiei standard și a ultrasonografiei cu substanță de contrast în contextul evaluării maladiilor hepatice.

Capitolul 2 „**Imagini biomedicale**”, descrie:

- Considerații generale privind prelucrarea imaginilor biomedicale
- Ultrasonografia și imagini ultrasonografice
- Ultrasonografia abdominală
- Zgomotul în imagini ultrasonografice

În capitolul 3 „**Tehnici de estimare robustă în vederea artificială**”, se realizează o descriere teoretică a algoritmilor robusți în contextul utilizării lor în extragerea parametrilor de clasificare pentru steatoză și a generării curbei intensitate-timp din CEUS. În imaginile medicale ultrasonografice apar inadvertențe legate de selecția regiunii de interes, deplasarea sondei și de zgomot. Datele utile se îmbină cu cele eronate și nu pot fi estimate cu o distribuție Gaussiană, fiind necesare tehnici de estimare robustă. Acest capitol cuprinde estimatorul L, estimatorul M acesta fiind o generalizare a estimatorului de maximă verosimilitate, transformarea Hough, tehnică de votare unde spațiul parametrilor este definit prin celule acumulative, algoritmi RANSAC, MSAC, MLESAC, NAPSAC și algoritmul mean shift.

În capitolul 4 „**Evaluarea obiectivă asistată de calculator a imaginilor ultrasonografice cu steatoză**”, este prezentată o nouă metodă propusă pentru diagnoza folosind calculatorul a steatozei din imagini medicale ultrasonografice. În etapa de extragere a caracteristicilor s-au utilizat soluții robuste. În acest capitol se propun noi parametrii robusti de clasificare, se vorbește despre diagnosticarea automată folosind două variante ale clasificatorului Random Forests, ca în final să facem un studiu comparativ folosind două clasificatoare, Random Forests și SVM.

În capitolul 5 „**Extragerea optimizată a curbelor intensitate-timp în ultrasonografia de contrast**”, propunem o soluție robustă pentru extragerea curbei intensitate timp folosind filtrarea și urmărirea simultană a leziunilor hepatice focale din secvențe video CEUS. Verificăm eficacitatea metodei propuse și prezentăm rezultatele obținute. S-au urmat pașii:

- Determinarea cadrului din secvența CEUS cu leziunea hepatică
- Se selectează folosind un program de calculator regiunea de interes cu leziunea
- Propunerea și implementarea de tracking a leziunii folosind mean shift
- Definirea curbei intensitate timp cu metoda propusă

În capitolul 6 „**Concluzii generale și contribuții**”, conține principalele concluzii rezultate din teza de doctorat și contribuțiile originale ale doctorandului raportate în această teză.

## 1.4. Lucrări publicate sau prezentate de doctorand

### 1. Jurnale

**Dan Mihai Mihăilescu**, Vasile Gui, Corneliu Ioan Toma, Alina Popescu, Ioan Sporea, Computer Aided Diagnosis Method for Steatosis Rating in Ultrasound Images using Random Forests, Med Ultrason, Vol. 15, Number 3, pages 184-190, 2013, ISSN 1844-4172, doi: 10.11152/mu.2013.2066.153.dmm1vg2

### 2. Conferințe și workshop-uri

**Dan Mihai Mihăilescu**, Processing of Biomedical Images, workshop nr. 1, Interdisciplinaritatea și Managementul Cercetării, Universitatea "Politehnica" din Timișoara, România, Noiembrie 2011

Alina Popescu, Ioan Sporea, Vasile Gui, **Dan Mihai Mihăilescu**, Roxana Șirli, Mirela Dănilă, Ana Jurchiș, Melania Ardelean, Oana Grădinaru, Evaluarea Obiectivă Ecografică Asistată de Calculator a Steatozei Hepatice, A XV-a Conferință Națională a Societății Române de Ultrasonografie în Medicină și Biologie. Primul Simpozion de Educație Medicală folosind Ultrasonografia, Universitatea de Medicină și Farmacie "Iuliu Hațieganu" Cluj-Napoca, 31.05-02.06 2012, Cluj-Napoca

**Dan Mihai Mihăilescu**, Automatic Evaluation of Liver Steatosis from US Images, workshop nr. 2, Interdisciplinaritatea și Managementul Cercetării în Studiile Doctorale, Universitatea din Oradea, România, Iunie 2012

**Dan Mihai Mihăilescu**, Vasile Gui, Corneliu Ioan Toma, Alina Popescu, Ioan Sporea, Automatic Evaluation of Steatosis by Ultrasound Image Analysis, 2012 IEEE 10th International Symposium on Electronics and Telecommunications Proceedings ISETC 2012, Timișoara, România, ISBN 978-1-4673-1174-8, IEEE Catalog Number CFP 1203L-PRT

**Dan Mihai Mihăilescu**, Automatic Classification of Steatosis Stage from B mode Ultrasound Images, workshop nr. 3, Interdisciplinaritatea și Managementul Cercetării, Universitatea din Pitești, România, Mai 2013

**Dan Mihai Mihăilescu**, Vasile Gui, Corneliu Ioan Toma, Alina Popescu, Ioan Sporea, Simultaneous Filtering and Tracking of Focal Liver Lesion for Time Activity Curve Analysis in Contrast Enhanced Ultrasound Imagery, IEEE 12th International Symposium on Applied Machine Intelligence and Informatics, Herl'any, Slovacia, Ianuarie 2014, IEEE Catalog Number CFP1408E-PRT, ISBN 978-1-4799-3441-6

## **2. IMAGINI BIOMEDICALE**

Imagistica medicală include metodele folosite pentru achiziția imaginilor din corpul uman pe baza tehnicilor specializate și a calculatoarelor. Inițial imaginile sunt achiziționate ca apoi să fie stocate în format digital. Pentru a obține imagini medicale a corpului uman este nevoie de o anumită formă de energie. În radiologie sunt utilizate razele X, extrem de invazive, pentru penetrarea unei porțiuni a corpului uman. Razele X sunt o formă de radiație electromagnetică. Tomografia computerizată utilizează razele X alături de algoritmi de calcul pentru a crea imagini medicale. Imagistica prin rezonanță magnetică – tehnologia RMN, produce o imagine a regiunii corpului prin intermediul unui câmp magnetic și a undelor sonore. În ultrasonografie sunt utilizate semnalele (unde sonore) de înaltă frecvență. Acest tip de imagini oferă informații ce definesc anatomia umană. Imaginile medicale conțin datele necesare cercetării noastre și care pot fi procesate pentru prelucrarea particulară a datelor. Cercetările din domeniul prelucrării și evaluării imaginilor biomedicale au dus la apariția unor aparate tot mai performante de imagistică medicală.

### **2.1. Considerații generale privind prelucrarea imaginilor biomedicale**

Procesarea imaginilor medicale oferă informații specifice suplimentare din imagine. Corpul uman furnizează imagini obținute in-vivo, adică pacientul este în viață în momentul investigației. Acest lucru denotă că pacientul nostru respiră, adică plămânii funcționează, inima are o oscilație periodică, iar arterele și venele conțin sânge în mișcare. Aceste mișcări interioare organismului, fac ca imaginea biomedicală să conțină numeroase neregularități. O altă influență negativă asupra imaginilor biomedicale o au artefactele. Acestea trebuie diminuate sau eliminate pe cât posibil. O parte din aceste elemente nedorite apar în urma tehnicilor de înregistrare, a codificării sau comprimării digitale.

### **2.2. Ultrasonografia și imagini ultrasonografice**

Ultrasonografia utilizează semnale cu frecvențe mai mari de 2 Mhz pentru a genera imagini medicale. Numele de ultrasonografie generală are la bază folosirea în examinare a sunetelor de frecvență înaltă (ultrasunete). Acestea sunt unde sonore cu o frecvență mai mare decât aceea pe care pot să o perceapă organele auditive. Imaginile ultrasonografice se obțin în timp real, fiind ușor de vizualizat.

Ultrasonografia poate fi utilizată pentru vizualizarea structurilor interne ale organismului. Folosind o sondă ultrasonografică (transductor - transducer), în corpul uman este emis un semnal ultrasonic. Semnalul este reflectat de țesutul aflat pe direcția acestuia și recepționat de emițător. Ultrasonografia este utilizată pe scară

largă în medicină, fiind aplicată cu succes pentru evaluări medicale dar și pentru proceduri terapeutice, adică în intervenții cum ar fi la biopsii[1] și puncții.

Ultrasonografia medicală este utilizată pentru evaluarea mai multor boli ce afectează pacienții:

- anestezie, pentru ghidarea operatorului în efectuarea procedurii medicale existând riscul de a afecta zone adiacente punctului de aplicare
- cardiologie, pentru diagnosticarea funcționării corecte a valvelor și a ventricolelor precum și evaluarea variațiilor în volum ale inimii
- în medicină de urgență la investigarea organelor interne în urma traumatismelor
- în ultrasonografia abdominală, la evaluarea organelor interne: ficat, vezică biliară, pancreas, rinichi
- obstetrică-ginecologică
- otorinolaringologie (ORL), tratarea diverselor boli ale gâtului
- neonatologie, în investigațiile efectuate copiilor cu vârstă mai mică de un an
- oftalmologie, ultrasonografie oculară
- urologie, în tratamentul aparatului renal
- sistem vascular, permeabilitatea și obstrucția vaselor sanguine
- ultrasonografia folosită în investigațiile glandei tiroide
- ultrasonografia mamară

Ultrasonografia cu substanță de contrast (Contrast Enhanced Ultrasonography, CEUS) este o metodă modernă, folosită în investigațiile medicale, ce utilizează ecogenitatea substanței de contrast pentru generarea imaginilor medicale. Este o metodă de investigație modernă și non-invazivă, administrarea substanței de contrast precede monitorizarea ultrasonografică, fiind aplicată intravenos pacientului cu rezultate bune în investigarea leziunilor hepatice focale [2].

Avantajele ultrasonografiei cu substanță de contrast [3]:

- este ușor de efectuat
  - este repetabilă și cu un cost mai redus în comparație cu tomografia computerizată și imagistica pe bază de rezonanță magnetică.
  - este non-invazivă, corpul nu este supus iradierii
  - substanța de contrast este inertă chimic
  - acces la imagini în timp real [49]
  - substanța de contrast este bine tolerată de corpul uman și se elimină ușor prin respirație (plămâni).
- se poate efectua pacienților ce au implanturi metalice în organism și deasemenea celor cu insuficiență renală

În concluzie ultrasonografia cu substanță de contrast având un cost redus, fiind neiradiantă și foarte bine tolerată de corpul uman nu elimină utilizarea altor metode imagistice dar de cele mai multe ori le înlocuiește cu succes. Dezavantaje ale acestei metode:

- acuratețe mai scăzută în cazul pacienților obezi
- durata examinării este oarecum limitată, microbulele nu persistă prea mult timp în sistemul sanguin

Introducerea în practica medicală actuală a substanțelor de contrast și implementarea unui protocol de lucru au făcut să crească substanțial sensibilitatea și specificitatea acestei tehnici în detectarea și caracterizarea leziunilor hepatice focale [4].

Realizarea ultrasonografiei cu substanță de contrast, din prezenta lucrare, când discutăm de leziuni hepatice constă în monitorizarea a trei faze.

Prima fază începe din momentul apariției intensificării în secvența video CEUS și ține până la momentul maxim al intensificării, urmată fiind de celelalte două faze.

Fața de CT și RMN, un avantaj al CEUS este posibilitatea de a monitoriza perioada de umplere cu agent de contrast în timp real.

### 2.3. Ultrasonografia abdominală

În acest subcapitol descriem doar ultrasonografia abdominală folosită în tratamentul organelor interne. Ea este efectuată de gastroenterologi, radiologi, sonografiști, sau medici specialiști în medicină internă. Folosește transmisia și reflexia ultrasunetelor pentru vizualizarea organelor interne prin peretele abdominal, din acest motiv procedura mai poartă numele de ultrasonografie transabdominală. Medicul care efectuează ultrasonografia folosește o sondă manuală.

Ecografia abdominală este utilizată la evaluarea unor organe cum sunt ficat, pancreas, precum și la monitorizarea vaselor sanguine. Ultrasunetele se propagă foarte bine într-un mediu lichid, astfel această metodă este utilizată la vizualizarea vezicii urinare. Pentru aceasta este indicat ca pacientul să consume multe lichide în prealabil. Pentru ficat ultrasonografia abdominală este utilă în evaluarea gradului de severitate a steatozei hepatice, iar ultrasonografia cu substanță de contrast se folosește la diferențierea leziunilor hepatice.

Ultrasonografia cu substanță de contrast (CEUS) a fost folosită la începuturi în tratamentul medical al sistemului circulator, ca apoi să fie utilizată cu succes în evaluarea leziunilor hepatice. Folosind ultrasonografia cu substanță de contrast se poate vizualiza circulația sanguină a ficatului și dezvoltarea tumorilor hepatice.

Leziunile hepatice se diferențiază în leziuni benigne și maligne care cu ajutorul ultrasonografiei cu substanță de contrast se diferențiază cu o mai mare acuratețe.

Leziuni hepatice benigne:

- hemangiom – de obicei în examinarea folosind ultrasonografia standard, hemangiomele din ficat sunt descrise ca fiind hiperecogenice cu intensificare omogenă, bine delimitate cu un diametru de până la 3 centimetri și care prezintă amplificare posterioară. În unele cazuri aspectul leziunii este hipoecogenic cu un diametru mai mare de 3 centimetrii. Acest lucru implică o diagnoză diferențiată și utilizarea substanței de contrast.
- hiperplazie nodulara focală – întâlnită mai des la femei datorită utilizării contraceptivelor orale
- adenom hepatic – în general apariție solitară, cu un procentaj mai mare la femei
- chisturi complexe – chisturi biliare hemoragice
- hematoame hepatice

Leziuni hepatice maligne:

- carcinom hepatocelular – cea mai des întâlnită leziune malignă a ficatului, reprezentând 70-85% din tumorile hepatice maligne primare, de obicei are la bază ciroza hepatică
- colangiocarcinom – intensificare rapidă în faza arterială
- adenocarcinom biliar – tumoare chistică malignă foarte rară
- metastaze

Ultrasonografia este o modalitate excelentă de imagistică pentru detectarea tumorilor hepatice (leziuni focale). Avantaje: metodă eficientă din punct de vedere

al costului, fără radiații, repetabilă, acces la imagini în timp real. Ca dezavantaj, evaluarea leziunilor hepatice focale (eng. FLL) poate fi foarte costisitoare (CT, RMN și / sau CEUS) și de obicei, este foarte stresantă pentru pacienți.

## 2.4. Imagini ultrasonografice

La utilizarea imaginii diagnostic o importanță deosebită o are calitatea ei. Această calitate a imaginilor ultrasonografice este dată de produsul îmbinărilor între performanța operatorului și aparatul utilizat. Se poate da un exemplu: calitatea imaginii poate fi influențată atât de operator cât și de aparatul utilizat (avem două situații, un operator bun cu un aparat mai puțin performant sau un aparat ultraperformant și operator începător). Un element care influențează claritatea imaginii sonografice este zgomotul.

### 2.4.1. Zgomotul în imagini

Zgomotul este un semnal aleator, ce afectează informația utilă într-o imagine medicală ultrasonografică. El este un element perturbator a cărui valoare se dorește a fi cât mai mult diminuată. Pentru diminuarea lui se încearcă diverse metode de filtrare. Zgomotul se suprapune peste imagini în două moduri: aditiv și multiplicativ.

- aditiv adică zgomotul se însumează cu imaginea

$$f(x, y) = i(x, y) + zg(x, y) \quad (2.1)$$

unde  $i(x, y)$  definește valoarea pentru intensitate în imagine, iar  $zg(x, y)$  reprezintă nivelul de zgomot.

- multiplicativ adică zgomotul se înmulțește cu imaginea

$$f(x, y) = i(x, y) * zg(x, y) \quad (2.2)$$

În imagini medicale ultrasonografice se manifestă zgomotul de tip speckle, acesta fiind un zgomot de tip multiplicativ și se regăsește permanent în imaginile ultrasonografice. O proprietate a zgomotului multiplicativ este aceea că media este direct proporțională cu dispersia zgomotului. Filtrarea zgomotului de tip speckle se poate efectua cu operatorul median. Fie  $x_1, x_2, \dots, x_n$  un set de variabile aleatoare ce alcătuiesc o distribuție. Zgomotul de tip speckle este caracterizat de o distribuție Laplace având funcția densitate de probabilitate (fdp):

$$p(x_i | \theta, a) = \frac{1}{2a} \exp\left(-\frac{|x_i - \theta|}{a}\right) \quad (2.3)$$

În ecuația (2.3),  $\theta$  este un parametru de locație, iar  $a \geq 0$  este un parametru de scară. Funcția densitate de probabilitate a distribuției Laplace este exprimată ca o diferență absolută față de medie, în timp ce distribuția normală este văzută ca



diferența față de medie ridicată la pătrat. Întâlnim și alte tipuri de zgomot ce diferă prin distribuția ce le caracterizează, cum ar fi: Cauchy, Beta, Gamma, Maxwell și altele. De exemplu, funcția densitate de probabilitate pentru o distribuție Cauchy este:

$$f(x_i | z_0, \gamma) = \frac{1}{\pi\gamma \left[ 1 + \left( \frac{x_i - z_0}{\gamma} \right)^2 \right]} \quad (2.4)$$

unde  $z_0$  este parametrul ce conține informația de locație și care stabilește punctul unde funcția are valoarea maximă, în timp ce  $\gamma$  este un parametru de scară. Zgomotul definit de o distribuție gamma, pentru  $x_i$  strict pozitiv, are funcția densitate de probabilitate:

$$f(x_i | k, \theta) = x_i^{k-1} \frac{1}{\theta^k \Gamma(k)} \exp\left(-\frac{x_i}{\theta}\right) \quad (2.5)$$

unde  $\Gamma(k)$  reprezintă funcția gamma a lui  $k$ . În ecuația (2.5),  $k > 0$  este un parametru ce caracterizează forma, iar  $\theta > 0$  este parametrul de scară. Deoarece zgomotul nu este dorit în imaginile medicale, se caută metode de modelare și de eliminare a acestuia.

### 2.4.2. Concluzii

Zgomotul degradează calitatea imaginii medicale ultrasonografice. Reducerea pe cât posibil a influenței zgomotului reprezintă un obiectiv important în prelucrarea imaginilor în general și cu atât mai mult în imagini biomedicale.

### 3. TEHNICI DE ESTIMAȚIE ROBUSTĂ ÎN VEDEREA ARTIFICIALĂ

Teoria estimației urmărește evaluarea parametrilor unei distribuții în general cunoscute. Valorile numerice obținute se numesc estimații sau estimatori. Un estimator încearcă să aproximeze parametrii necunoscuți prin folosirea datelor apriorice. Tehnicile de estimație robustă au un rol important în vederea artificială. Prin estimare robustă se înțelege acea tehnică de estimare care este insensibilă la valori aberante sau „outliers”. Aceste valori sunt niște rezultate care nu se potrivesc cu un model înainte stabilit al estimării parametrilor. Ele pot să apară în urma unor erori de măsurare, a zgomotului, sau a unei interpretări greșite a datelor făcute de cititor. Ele pot fi create special pentru un domeniu cu scopul obținerii unui rezultat cât mai real, sau pot fi adoptate din statistică. Tehnicile robuste au o finalitate practică în estimarea parametrilor ce caracterizează un obiect în imagine.

Aceste tehnici de estimare robustă pot fi: parametrice, caz în care funcția densitate de probabilitate (pdf) este presupusă ca fiind cunoscută, dar este necesară estimarea unor parametri pentru a se potrivi cu datele experimentale și metodele neparametrice în care funcția densitate de probabilitate (pdf) este necunoscută, iar scopul lor este de a estima această funcție prin presupuneri minime despre structura funcției. Un manual de referință în statistici robuste este [5].

O măsură de robustețe ce caracterizează aceste tehnici este punctul de frângere (breakpoint) [6] reprezentând procentajul maxim de date eronate pe care estimarea robustă îl poate lua fără ca soluția să fie greșită. Metoda celor mai mici pătrate (LS) [6] are punctul de frângere la zero adică o singură dată aberantă poate compromite complet estimarea, indiferent de numărul de date conforme. LMedS [7] alături de mediană, au punctul de frângere la 50% din cauză că jumătate din date pot fi aberante fără a influența semnificativ estimarea.

Funcția de influență [8][9] este o măsură de robustețe, ce evaluează variația produsă de o dată suplimentară neconformă asupra estimatei curente, ca funcție de reziduul produs, reprezentând distanța față de estimata curentă neafectată. În cazul metodei celor mai mici pătrate funcția de influență este proporțională cu distanța de la punct la estimată, ceea ce face ca punctele neconforme să producă devieri mari ale estimatei. Pentru a obține o robustețe funcția de influență ar trebui să tindă la zero pe măsură ce distanța crește.

Variația statistică este o altă măsură de robustețe ce caracterizează tehnicile de estimare robustă și este raportul dintre dispersia (varianța) unui estimator nedepășat optimal pentru un anumit model, de obicei se consideră cel Gaussian și dispersia (varianța) estimatorului robust în cauză.

Estimarea robustă mai poate fi definită ca și o problemă de separare a distribuțiilor [10]. În estimarea robustă întâlnim două distribuții, distribuția plauzibilă și o distribuție necunoscută, aberantă. Această metodă de clasificare ne conduce la două modele de erori: eroare de tip I apare atunci când un eșantion aberant este considerat plauzibil și eroare de tip II când un eșantion plauzibil este considerat aberant.

Principiul celor mai mici pătrate stă la baza metodei minimizării mediane pătratelor reziduurilor LMedS [11][7]. Un alt grup de estimatori ce au la bază principiul verosimilității maxime sunt estimatorii M [8], cu o robustețe superioară.

Un estimator des întâlnit este estimatorul RANSAC [12]. Acesta utilizează submulțimi din setul de date, extrase prin eșantionare aleatoare, pentru a genera o mulțime de soluții candidate la valorile parametrilor căutați. Soluția corectă este aceea care întrunește cel mai mare consens, în urma verificării eșantioanelor de date, în limite de precizie prestabilite.

### 3.1. Estimatorii L

Estimatorul L este o combinație liniară a statisticilor de ordonare extrase din setul de date. Fiecare element al setului de observații ordonat este ponderat în funcție de poziția acestuia în șir. Două avantaje importante ale utilizării estimatorilor L constă în faptul că sunt ușor de aplicat, iar o parte din aceștia au calitatea de a fi robuști. Considerând sortarea datelor, estimatorul este ușor de interpretat și calculat, fiind rezistent la date aberante, având aplicații în tehnici robuste, statistică, vedere artificială și atunci când întâlnim calcule complexe. Cu toate acestea au și impedimente, iar în calcule sunt preferați estimatorii de tip M deși au o complexitate mai ridicată. O prezentare a estimatorului de tip L apare în [9].

În multe situații estimatorul L conduce la rezultate bune, având o utilitate în statistica robustă. Exemplu: Se consideră un set de date compus din  $N$  de elemente. În urma ordonării crescătoare, extremele,  $n_0, \dots, n_9$  și  $n_{N-10}, \dots, n_{N-1}$  sunt eliminate. Celelalte elemente sunt ponderate în funcție de poziția lor în șir, rezultând estimata dorită.

Se pot enumera o serie de estimatori L: minimul, maximul, mediana, mid-range, trimmed range, distanța intercuantilă, media într-o fereastră, minimul mediane pătratelor.

Estimatorii L au un punct de ruptură ridicat, fiind rezistenți la date aberante și prin urmare robuști. Punctul de ruptură este dat de procentul din setul de date ce poate lua valori aberante fără ca estimata să se deplaseze îngrijorător de mult față de model. Minimul și maximul pot fi considerați estimatori L ce nu fac parte din categoria celor robuști având punctul de ruptură egal cu zero. Media și mid-range într-o formă ajustată pot deveni estimatori robuști.

Avantajele estimatorilor L constă în simplitatea și robustețea lor, fiind folosiți înaintea apariției calculatoarelor, pentru obținerea de informații cu un volum minim de muncă.

Eficiența lor constă în rapiditatea cu care se realizează estimarea și arată că statisticile bazate pe ordonare, conțin o cantitate însemnată de informație.

### 3.2. Estimatorul LMedS

Estimatorul LMedS este definit de Rousseeuw în [7]. Acesta are ca punct de plecare metoda celor mai mici pătrate.

Dacă setul de date este contaminat cu valori aberante metoda celor mai mici pătrate prezintă o lipsă de robustețe. De exemplu, în cazul regresiei unui set de puncte la o dreaptă, metoda celor mai mici pătrate minimizează suma pătratelor distanțelor euclidiene a punctelor la dreapta estimată. Eroarea de estimare prezintă un ordin de mărime ridicat, dacă există o singură valoare aberantă. Estimatorul

„LmedS” înlocuiește „suma pătratelor” cu mediana, acest lucru conducând la proprietatea de robustețe a acestui estimator. De menționat că mediana are punctul de frângere la valoare de 0.5.

Rousseeuw [7] definește modelul liniar  $y_i = x_{i1}\theta_1 + x_{i2}\theta_2 + \dots + x_{ip}\theta_p + e_i$ , cu ( $i=1\dots n$ ), unde valorile  $e_i$  se supun unei distribuții normale având media zero și deviația standard  $\sigma$ . Se dorește estimarea lui  $\theta = (\theta_1, \theta_2, \dots, \theta_p)^t$  pe baza datelor  $(x_{i1}, x_{i2}, \dots, x_{ip}, y_i)$ . Estimatorul medianei pătratelor reziduurilor este definit prin ecuația:

$$\min_{\hat{\theta}} \text{med } r_i^2 \quad (3.1)$$

unde  $r_i$  sunt reziduurile de forma  $y_i - x_{i1}\hat{\theta}_1 - \dots - x_{ip}\hat{\theta}_p$ .

### 3.3. Estimatorii M

Estimatorii de verosimilitate maximă (MLE) determină vectorul de parametri care maximizează probabilitatea obținerii datelor existente la momentul estimării. Din [13], putem deduce următoarele proprietăți ale MLE: suficiența (date complete despre parametrul țintă conținute în estimator), invariația la parametrizare (aceeași soluție MLE obținută independent de parametrizare), consistența (valoarea parametrului care a generat datele, recuperată asimptotic), eficiența (dispersia cea mai mică posibilă a estimatelor parametrului). Aceste caracteristici nu se regăsesc la metoda celor mai mici pătrate.

Se consideră  $n$  valori,  $x_1, x_2, x_3, \dots, x_n$ , ce formează o distribuție, cu funcția densitate de probabilitate  $p(x|\theta)$ , ce depinde de parametrul  $\theta$ . Valorile setului  $n$  sunt considerate a fi independente. Din setul de  $n$  valori ales trebuie estimată valoarea lui  $\theta$  pe baza funcției de verosimilitate:

$$M(\theta) = \prod_{i=1}^n p(x_i | \theta) \quad (3.2)$$

reprezentând probabilitatea pentru setul ce cuprinde  $n$  date, în funcție de parametrul  $\theta$ . Din punct de vedere al calculului matematic este mai ușor de lucrat cu logaritmul funcției  $M(\theta)$  sau cu forma negativă a logaritmului:

$$N(\theta) = -\ln M(\theta) = -\sum_{i=1}^n \ln p(x_i | \theta) \quad (3.3)$$

Pentru găsirea valorii estimatei  $\hat{\theta}$  pe baza lui  $\theta$ , folosind metoda de maximă verosimilitate, maximizăm  $M(\theta)$  sau minimizăm forma negativă a lui  $M(\theta)$ . Estimatorul verosimilitatii maxime pentru  $\theta$  este dat de ecuația:

$$\hat{\theta} = \arg \min_{\theta} N(\theta) \quad (3.4)$$

Legătura dintre estimatorii M și estimatorii de maximă verosimilitate se face prin intermediul unei funcții de pierdere  $\rho(\cdot)$ , sau normă a erorii.

Funcțiile de pierdere pot fi interpretate ca logaritmi ai funcțiilor densitate de probabilitate a erorii:

$$\rho(u) = -\ln p(u) \quad (3.5)$$

Semnul minus din ecuația de mai sus are ca rezultat transformarea problemei de maxim, rezolvate de estimatorii de maximă verosimilitate în probleme de minim rezolvate de estimatorii M.

Estimatorii M definesc o funcție obiectiv, sau funcție de pierdere  $\rho(\cdot)$ , ce acoperă un spectru mai larg în comparație cu estimatorii de verosimilitate maximă și pot fi definiți ca o generalizare a estimatorilor de maximă verosimilitate. Estimatorii de maximă verosimilitate corespunzători modelelor de zgomot Gaussian și respectiv Laplacian sunt cazuri particulare ale estimatorilor M. Estimatorii M sunt soluția ecuației:

$$\min \left( \sum_{i=1}^n \rho(u_i) \right) \quad (3.6)$$

unde  $u_i$  reprezintă eroarea sau rezidualul experimental  $i$ , adică diferența dintre observația  $i$  și valoarea dată de model. Metoda celor mai mici pătrate LS (Least Squares) minimizează suma pătratelor reziduurilor:

$$\sum_i u_i^2 \quad (3.7)$$

Ecuația (3.7) este puternic influențată de date neconforme. Estimatorii M au rolul să reducă efectul reziduurilor generate de date neconforme prin înlocuirea ecuației (3.7) cu ecuația (3.6). Ecuația de mai jos definește soluția estimatorului M:

$$\hat{\theta} = \arg \min_{\theta} \sum_{i=1}^n \rho(u_i | \theta) \quad (3.8)$$

Estimatorii M pot fi clasificați pe baza alurii funcției de influență:

$$\psi(x) = \frac{d\rho(x)}{du} \quad (3.9)$$

Funcția de influență denotă cât de mult sunt afectați de către o observație parametrului ce se estimează. Se poate spune că un estimator este robust dacă influența generată de o singură observație este atenuată astfel încât să nu permită o deplasare semnificativă a estimatei. Întâlnim trei clase de estimatori M:

- estimatori ce au o funcție de influență monotonă
- estimatori cu funcție de influență ce se anulează la infinit
- estimatori cu funcție de influență ce se anulează la un orizont finit

### 3.4. Transformarea Hough

Tehnicile bazate pe votare tind să grupeze datele în jurul unor ipoteze spre deosebire de estimatorii de tip M ce încearcă să găsească parametrii unui model pentru întregul set de date printr-o ponderare mai slabă a datelor neconforme. Una din tehnicile de votare întâlnite în analiza imaginilor este transformarea Hough [14]. În forma ei inițială transformarea a fost propusă pentru detecția liniilor dar ea se poate generaliza pentru forme aleatoare. Spațiul parametrilor este cuantizat pe un număr de celule acumulative. Fiecare eșantion de date adaugă un vot la toate celulele acumulative ale parametrilor care ar fi putut genera acea dată. Coordonatele celulelor care acumulează un număr mare de voturi sunt soluțiile problemei.

Considerăm  $n$  puncte de muchie detectate și cautăm submulțimi ale acestor puncte, situate pe aceeași dreaptă. O tratare posibilă, dar ingenuă a problemei, constă în a determina întâi toate dreptele definite de toate perechile de puncte de muchie din imagine, ca apoi a se stabili pentru fiecare dreaptă posibilă punctele ce-i aparțin. Avem  $N(N-1)/2$  drepte, astfel că avem de efectuat aproximativ  $N^3$  verificări, conform  $N[N(N-1)/2]$ , de unde rezultă un efort de calcul care pune opreliști pentru majoritatea aplicațiilor. Prin utilizarea transformării Hough [14] acest efort se reduce considerabil.

Fie două puncte oarecare  $(x_1, y_1)$  și  $(x_2, y_2)$  din spațiul imagine, definit de axele de coordonate  $x$  și  $y$ . Prin fiecare punct  $(x_i, y_i)$  trec o infinitate de drepte, definite de o ecuație de forma:

$$y_i = mx_i + n \quad (3.10)$$

Fiecare din aceste drepte se proiectează într-un punct distinct în planul parametrilor  $(m, n)$ . Toate dreptele ce trec prin punctul oarecare  $(x_i, y_i)$  pot fi reprezentate cu o singură dreaptă în spațiul parametrilor  $(m, n)$ . Ecuația rămâne în forma (3.10) cu observația că  $x_i$  și  $y_i$  sunt parametrii constanți, iar  $m$  și  $n$  sunt variabilele independente. Fiecărui punct de coordonate  $(x_i, y_i)$  îi atașăm o asemenea dreaptă în spațiul parametrilor (Fig. 3.1.).




Fig. 3.1 Transformarea Hough pentru detecția liniilor drepte

Fiecare punct al unei drepte din spațiul parametric, trasată pentru un punct  $(x_i, y_i)$ , definește unic o dreaptă particulară din spațiul de coordonate  $(x, y)$ , ce trece prin punctul  $(x_i, y_i)$ . Cele două drepte din spațiul parametrilor trasate pentru  $(x_1, y_1)$  și  $(x_2, y_2)$  se intersectează în punctul de coordonate  $(m_0, n_0)$  (Fig. 3.1.). Punctul  $(m_0, n_0)$  definește dreapta ce trece prin  $(x_1, y_1)$  și  $(x_2, y_2)$ . Ecuația acestei drepte este:

$$y = m_0x + n_0 \quad (3.11)$$

Toate dreptele din spațiul parametrilor, corespunzătoare unor puncte de forma  $(x_i, y_i)$  situate pe dreapta ce trece prin punctele  $(x_1, y_1)$  și  $(x_2, y_2)$ , se vor intersecta în  $(m_0, n_0)$ . Astfel, putem determina numărul de puncte situate pe dreapta definită de parametrii  $(m_0, n_0)$ , numărând intersecțiile din punctul respectiv în planul parametrilor.

Practic, la aplicarea unui algoritm de detecție prin transformare Hough, spațiul parametrilor se cuantizează pe un număr finit de celule acumulatori,  $A(p, q)$ . Distincția de cuantizare determină precizia impusă condiției de coliniaritate. Pentru a crește robustețea, precizia nu trebuie să depășească cerințele minimale impuse de aplicație.

Considerăm că ne interesează drepte cu parametrii cuprinși în intervalele  $(m_{\min}, m_{\max})$ , respectiv  $(n_{\min}, n_{\max})$ . Pentru o cuantizare liniară a intervalului  $(m_{\min}, m_{\max})$  pe  $M$  niveluri, se definește:

$$\Delta m = \frac{m_{\max} - m_{\min}}{M} \quad (3.12)$$

și

$$p = \frac{m}{\Delta m} \quad (3.13)$$

$$p_{\max} = \frac{m_{\max}}{\Delta m} \quad (3.14)$$

$$p_{\min} = \frac{m_{\min}}{\Delta m} \quad (3.15)$$

unde împărțirea se face prin rotunjire la numărul întreg cel mai apropiat. La fel se va proceda și pentru variabila  $n$ . La început,  $A(p,q)=0$ . Dăm lui  $m$  toate valorile  $m_p=p\Delta m$  admisibile și îl calculăm pe  $n$  din ecuația (3.10),  $n_i=y_i-m_p x_i$ , pentru fiecare din cele  $N$  puncte  $(x_i, y_i)$  detectate. Prin cuantizarea  $q=n/\Delta n$ , îl obținem pe  $q$  și incrementăm celula acumulatorului  $A(p,q)$ . Vor fi necesare  $M$  operații pentru fiecare punct  $(x_i, y_i)$ , complexitatea de calcul având ordinul  $MN$ . Numărul de operații efectuate crește proporțional cu  $N$ , spre deosebire de  $N^3$ . Este necesară identificarea punctelor de maxim în spațiul parametrilor, pentru detecția dreptelor, respectiv a celulelor  $A(p,q)$  ce au obținut valori acumulate mari. Astfel, parametrii  $(p,q)$  ai celulelor găsite identifică dreptele detectate. Folosirea ecuației (3.10) în reprezentarea dreptelor este convenabilă pentru primii pași în studiul tehnicilor de votare folosind transformarea Hough. Însă ea prezintă un dezavantaj care arareori poate fi neglijat. Parametrul  $m$ , ce reprezintă panta dreptei, tinde la infinit pentru dreptele cu orientare apropiată de axa verticală,  $y$ . Folosind reprezentarea dreptelor cu ajutorul ecuației de forma:

$$x \cos \theta + y \sin \theta = \rho \quad (3.16)$$

dezavantajul prezentat anterior poate fi cu ușurință eliminat.

Semnificațiile parametrilor  $\theta$  și  $\rho$  rezultă din figura 3.2.

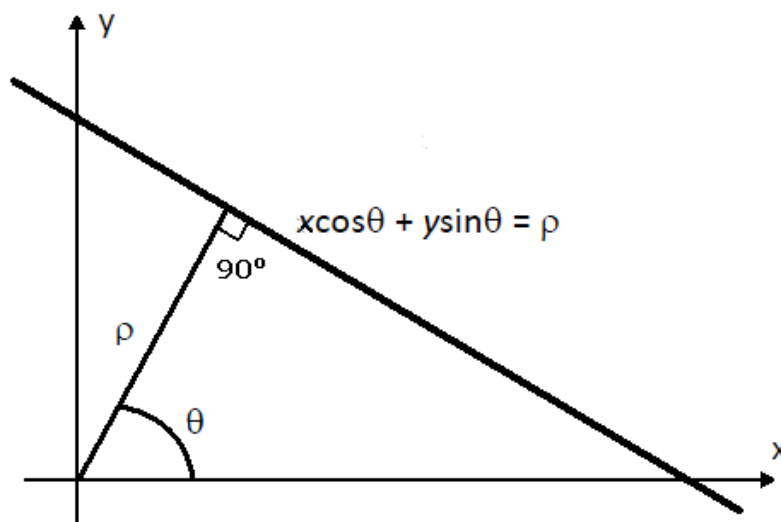


Fig. 3.2 Reprezentarea dreptei prin ecuația normală



Toate dreptele ce trec printr-un punct caracteristic  $(x_i, y_i)$ , se proiectează în planul parametrilor  $\rho, \theta$  pe o curbă sinusoidală. Pentru aceasta notăm  $\tan \alpha = y/x$ , iar ecuația (3.16) devine:

$$\cos(\theta - \alpha) = \rho \cos \alpha \quad (3.17)$$

Pentru valori constante ale coordonatelor  $(x_i, y_i)$ , unghiul  $\alpha = \alpha_i$  este constant, prin urmare și  $1/\cos \alpha_i = \text{constant}$ , atunci  $\rho$  devine produsul dintre o constantă și  $\cos(\theta - \alpha_i)$ .

Transformarea Hough poate fi definită pentru orice curbă ce poate fi modelată printr-o ecuație de forma  $f(\mathbf{v}, \mathbf{p})=0$ , unde  $\mathbf{v}$  este vector al coordonatelor iar  $\mathbf{p}$  un vector al parametrilor. În cazul unui cerc avem ecuația:

$$(x - p_1)^2 + (y - p_2)^2 = p_3 \quad (3.18)$$

Transformarea Hough se poate utiliza la detecția cercurilor prin găsirea maximelor acumulate în celulele unui spațiu tridimensional al parametrilor  $(p_1, p_2, p_3)$ . Metoda este aplicabilă mai ales pentru formele ce pot fi reprezentate analitic prin curbe definite de un anumit număr moderat de parametrii (parabole, elipse, linii), dar poate fi extinsă pentru a permite detecția unor curbe fără o reprezentare analitică explicită.

### 3.5. Algoritmul RANSAC

RANSAC [12] este una dintre cele mai bune metode de estimare robustă. RANSAC este abrevierea de la Random Sample Consensus. Este o metodă iterativă ce estimează parametrii unui model matematic dintr-un set de date care conțin date neconforme. Acum mai bine de 20 de ani Fischler și Bolles [12] au introdus această metodă, iar mai târziu Rousseeuw și Leroy [6] au atașat-o la literatura statistică. De atunci și până în prezent această metodă a fost folosită în multe aplicații de inteligență artificială și se pretează a fi utilizată în analiza automată a imaginilor. Este capabil să genereze o estimată a modelului pe baza unui set de date ce conține un număr mare de date neconforme. El este o combinație între un algoritm de verificare și o metodă de generare de soluții ipotetice.

Pentru generarea de soluții ipotetice se alcătuiesc  $Q$  seturi minimale de date prin eșantionare aleatoare. Setul minimal conține numărul minim de puncte ce permite calculul unei soluții, deci generarea unei ipoteze pentru parametrii modelului  $\theta$ . Rațiunea pentru care se preferă setul minim de date în locul unui set extins ce ar duce la un calcul matematic supradimensionat este aceea că șansele ca setul minim să fie contaminat sunt minimizate. Prin utilizarea de seturi minimale se pot genera un număr mare de soluții candidate, crescând probabilitatea în găsirea unui consens corect.

Algoritmul de verificare folosește o funcție de cost,  $C(\hat{\theta})$ , pentru a găsi soluția cea mai apropiată de model. Funcția cost se calculează pentru toate soluțiile ipotetice. Soluția corectă este aceea care întrunește cel mai mare consens, în sensul că soluția este verificată de cel mai mare număr de eșantioane de date, în limitele unui anumit prag prestabilit. Cel mai mare număr de puncte ce verifică modelul furnizează estimata algoritmului. O proprietate remarcabilă a algoritmului RANSAC

este aceea că pentru generarea unei soluții corecte este necesară existența unui singur set de date, necontaminat de zgomot sau de erori de măsurare lucru ce ar determina corect parametrii  $\theta$  ai modelului.

Pașii algoritmului sunt prezentați mai jos:

- pentru  $i=0, n$ 
  - se alege un set minimal de date, prin eșantionare aleatoare
  - pe baza setului de date selectat se generează o soluție  $\hat{\theta}_i$
  - se calculează valoarea funcției de cost  $C(\hat{\theta}_i)$ , pentru a se găsi numărul de puncte care nu sunt în consens cu  $\hat{\theta}_i$
- se alege modelul,  $\hat{\theta}'$ , pentru care  $C(\hat{\theta}_i)$  este minim,  $\hat{\theta} = \arg \min_{\hat{\theta}_i} C(\hat{\theta}_i)$
- se generează estimata finală  $\hat{\theta}$ , folosind date conforme

În cazul în care punctele sunt afectate de zgomot sau erori de măsurare, diferența între  $\theta$  și  $\hat{\theta}$  poate fi foarte mare, atunci când numărul seturilor minimale utilizat este mic. Prin urmare se utilizează un prag T ce selectează corect numărul de puncte caracteristice conforme cu soluția. Eroarea calculată pentru fiecare pereche de puncte din setul de date este distanța la perechea de puncte candidată. Eroarea rezultată se va compara cu acest prag T pentru a defini perechea de puncte ca fiind conformă sau aberantă. Acest proces îl vom repeta de Q ori, ca în final să alegem setul de date care minimizează funcția de cost:

$$C = \sum_i \rho(r_i^2) \quad (3.19)$$

unde  $\rho()$  este funcția de pierderi definită prin ecuația:

$$\rho(r^2) = \begin{cases} 0, & r^2 < T \\ 1, & r^2 \geq T \end{cases} \quad (3.20)$$

iar r este reziduul de aproximare asociat unei date.

Pentru determinarea soluției algoritmului, ideal ar fi să se efectueze alegerea tuturor subseturilor posibile din datele avute la dispoziție, însă din punctul de vedere al dificultății de calcul acest lucru este deseori prohibitiv.

Având la dispoziție N date, dintre care  $M \leq N$  aparțin modelului, considerăm P probabilitatea de a găsi un set necontaminat de S date, din Q încercări. Determinăm numărul de seturi de date necesare pentru a genera cu probabilitatea dorită, P, soluția corectă. Procentul de date contaminate este definit prin ecuația:

$$\varepsilon = \frac{N - M}{N} \quad (3.21)$$

Probabilitatea de a avea un set de S date integral corecte este:

$$P_c = (1 - \varepsilon)^S \quad (3.22)$$

în timp ce probabilitatea ca setul să nu fie integral corect este  $1 - P_c$ . Probabilitatea ca niciunul din cele  $Q$  seturi de date selectate să nu fie integral conforme modelului este:

$$P_e = [1 - (1 - \varepsilon)^S]^Q \quad (3.23)$$

respectiv, probabilitatea de a avea cel puțin un set de date necontaminat este:

$$P = 1 - P_e \quad (3.24)$$

Prin impunerea probabilității  $P$  de a avea cel puțin un set de date necontaminat, respectiv o soluție corectă, se obține numărul minim de seturi de date pe care trebuie să-l folosim:

$$Q = \frac{\log(1 - P)}{\log[1 - (1 - \varepsilon)^S]} \quad (3.25)$$

Valorile numărului  $Q$  de seturi de eșantioane necesare, crește rapid cu dimensiunea setului minimal și cu procentul de date neconforme modelului. Observăm o creștere exponențială a numărului de seturi de date necesare cu dimensiunea spațiului parametrilor și a setului de date minimal. La fel este și efectul creșterii procentului de contaminare. Dacă procentul de date contaminate este necunoscut, atunci numărul de experimente necesar,  $Q$ , se poate recalcula după fiecare experiment, prin estimarea procentului de contaminare calculând raportul între numărul de eșantioane de date conforme corespunzătoare celui mai bun model găsit până la momentul respectiv și numărul total de eșantioane de date.

Acest algoritm este caracterizat de două avantaje: robustețea și viteza, iar utilizarea lui în practică necesită setarea a câtorva parametri critici. Pentru o selecție cât mai fină a parametrilor au fost propuși algoritmi MSAC, MLESAC, NAPSAC.

### 3.6. Algoritmul MSAC

MSAC (inspirat din estimatorii de tip M) este o variantă îmbunătățită a algoritmului RANSAC. A fost propusă de către Thorr și Zisserman în anul 1998 [15][16]. Deosebirea dintre cele două algoritme RANSAC și MSAC este următoarea: RANSAC potrivește parametrii modelului în scopul de a maximiza numărul de date conforme, pe când MSAC potrivește parametrii modelului în scopul de a maximiza verosimilitatea datelor conforme. Algoritmul MSAC este o variantă a RANSAC combinat cu un estimator M. La RANSAC datele conforme au o penalizare egală cu zero în timp ce datele neconforme au o penalizare constantă. Pentru MSAC se utilizează o funcție de cost unde datele conforme au o penalizare diferită de zero în funcție de reziduul aferent, iar datele neconforme au penalizare constantă la fel ca la RANSAC:

$$C = \sum_i \rho(r_i^2) \quad (3.26)$$

unde  $\rho()$  este definită prin ecuația:

$$\rho(r^2) = \begin{cases} r^2, & r^2 < T^2 \\ T^2, & r^2 \geq T^2 \end{cases} \quad (3.27)$$

Este de remarcat că metoda MSAC cât și RANSAC au același ordin de mărime în complexitatea de calcul.

### 3.7. Algoritmul MLESAC

MLESAC (Maximum Likelihood Estimation Sample Consensus) este o metodă de estimare a verosimilității logaritmice negative. Algoritmul este o adaptare a lui RANSAC și a fost dezvoltat de către Torr și Zisserman [16], soluția fiind generată pe baza setului de date de verosimilitate maximă, estimată folosind ipoteza distribuției gaussiene a erorilor datelor conforme modelului și a distribuției uniforme pentru datele neconforme modelului.

MLESAC urmărește ideea inițială din RANSAC, aceea a eșantionării aleatoare, în care seturi minimale de date sunt utilizate pentru a dezvolta o soluție candidată, iar datele rămase sunt folosite pentru evaluarea calitativă a fiecărei soluții candidate. Acest algoritm evaluează soluția prin reprezentarea erorii de distribuție ca un model de amestec între o distribuție gaussiană și una uniformă, parametrul de amestec fiind necunoscut. Distribuția mixturii este dată de parametrul  $\gamma$  și reprezintă probabilitatea apriorică a eșantioanelor conforme:

$$\rho(r^2) = p(r^2) = \left( \gamma \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{r^2}{2\sigma^2}\right) + (1-\gamma)\frac{1}{\nu} \right) \quad (3.28)$$

Pentru un set de  $n$  corespondențe, se minimizează negativul logaritmului funcției de verosimilitate,

$$-L = -\sum_{i=1}^n \log \left( \gamma \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left( -\frac{\sum_{j=1}^n (\underline{x}_i^j - \underline{x}_i^j)^2 + (\underline{y}_i^j - \underline{y}_i^j)^2}{2\sigma^2} \right) + \frac{1-\gamma}{\nu} \right) \quad (3.29)$$

În ecuația (3.29), simbolul  $\underline{x}$  indică valoarea corectă a lui  $x$ , unde  $x = \underline{x} + \Delta x$  reprezintă valoarea coruptă de zgomot, același lucru fiind aplicat și pentru  $\underline{y}$ . Parametrul  $\sigma$  reprezintă deviația standard a distribuției gaussiene,  $n$  dimensiunea datelor măsurate, iar  $\nu$  este dimensiunea ferestrei cu datele distribuite uniform. Cel

mai propabil model este acela care minimizează verosimilitatea negativă logaritmică. În [16] a fost prezentat MLESAC ca o soluție superioară a lui RANSAC, în multiple aplicații de vedere artificială.

Rezultatele MLESAC s-au dovedit a fi utile într-o serie de aplicații descrise în Torr [16], dar superioritatea nu a fost confirmată în toate aplicațiile care au utilizat-o ulterior.

### 3.8. Algoritmul NAPSAC

NAPSAC (N Adjacent Points Sample Consensus) este un estimator clasic cu performanțe superioare RANSAC în estimare. În cazul aplicațiilor cu zgomot ridicat (peste 40%) s-a demonstrat că algoritmul RANSAC este superior metodei de minimizare a mediane reziduurilor Least Median of Squares [17]. Acest lucru s-a dovedit a fi adevărat pentru cazurile în care 50% din date, sunt date neconforme, nivel la care LmedS eșuează (mediana devine un element ineficient de estimare a datelor conforme). Considerând că distribuția de date neconforme este necunoscută, algoritmul RANSAC ne va furniza cele mai precise estimate, deși va întâmpina probleme din cauza dimensiunii mari a spațiului și a zgomotului. Myatt [18] realizează un studiu în care folosește algoritmul RANSAC și arată că acesta devine ineficient pentru aplicațiile care lucrează în spații de dimensiuni mari cu zgomot ridicat, iar în încercarea de estimare a parametrilor modelului în condițiile mai sus amintite probabilitatea ca RANSAC să reușească fără a necesita un timp destul de mare de procesare devine nulă.

Pentru a evita eșecul metodei RANSAC în spații de dimensiuni mari, datorită unei selecții aleatoare de date obiective se poate îmbunătăți acest algoritm prin luarea în considerare a distribuțiilor datelor în spațiul multidimensional. În acest sens Myatt dezvoltă un nou algoritm [18] care se poate utiliza în locul procesului de eșantionare uniformă, în orice algoritm de estimare. NAPSAC propune un algoritm de eșantionare aleatoare eficientă, care are la bază ideea că eșantioanele conforme sunt grupate spațial în imagine. Pașii algoritmului sunt [18]:

- Din toate punctele se selectează aleator un punct inițial  $p_0$
- Într-o zonă de rază  $r$ , cu centrul în  $p_0$ , se identifică setul de puncte  $S_{p_0}$
- Algoritmul se întrerupe dacă numărul de puncte din  $S_{p_0}$  este mai mic decât dimensiunea setului minimal
- Vom selecta uniform puncte din  $S_{p_0}$  până când setul minimal a fost selectat, inclusiv  $p_0$ .

În situația în care punctul selectat aleator  $p_0$ , se încadrează într-un model, restul de puncte eșantionate adiacente, teoretic, vor avea o probabilitate mai mare de a fi date verosimile. În situația contrară, dacă este selectat un punct aberant, atunci datele adiacente acestuia vor avea șanse mai mici de a fi date verosimile. Dacă nu sunt suficiente puncte pentru a evalua modelul atunci eșantionul este abandonat. NAPSAC este mult mai eficient decât RANSAC în spații de dimensiuni mari.

În 2002, Tordoff a propus o variantă a metodei NAPSAC care folosește eșantionarea ghidată în locul celei aleatoare [19]. Tot aici mai putem aminti de algoritmul INAPSAC, versiune modificată a NAPSAC și prezentată în [20]. Un alt algoritm ce are punct de plecare RANSAC este MAC-RANSAC [21].

### 3.9. Algoritmul Mean Shift

Algoritmul neparametric mean shift este un algoritm eficient pentru estimarea locației modurilor densității de probabilitate. În urmă cu aproximativ 40 de ani Fukunaga și Hostetler [22] au introdus acest algoritm, ce a fost modernizat și utilizat în vederea artificială de Comaniciu și Meer [23][24]. Este un algoritm de tip gradient ascendent și este o metodă neparametrică din cauza estimatei densității și a gradientului densității folosind funcții nucleu. Avem versiuni diferite de mean shift deoarece funcțiile nucleu pot fi diferite.

Estimarea densității pe bază de funcții nucleu (cunoscută ca și tehnică cu fereastră Parzen în domeniul recunoașterii formelor) este cea mai utilizată metodă de estimare a densității de probabilitate. Calitatea estimatei funcției densitate de probabilitate depinde de alura funcției fereastră, numită și funcție nucleu a operatorului de estimare și de un parametru numit parametru de scară  $h$ .

Într-un spațiu  $d$ -dimensional se consideră un număr  $n$  de date  $\mathbf{x}_i$ , unde  $i$  ia valori de la 1 la  $n$ , cu o funcție de densitate de probabilitate  $p(\mathbf{x})$ . O estimată a acestei densități poate fi scrisă astfel:

$$\hat{p}_H(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n K_H(\mathbf{x} - \mathbf{x}_i) \quad (3.30)$$

unde

$$K_H(\mathbf{x}) = |H|^{-1/2} K_H(H^{-1/2}\mathbf{x}) \quad (3.31)$$

este funcția nucleu cu  $\mathbf{H}$  matricea de bandă (scară)  $d \times d$  simetrică și pozitiv definită, ce stabilește lărgimea de bandă a estimatorului. Uzual  $\mathbf{H}$  are formă diagonală,  $\mathbf{H} = \text{diag}[h_1^2, \dots, h_d^2]$ , mai mult pentru spații omogene, este preferată forma proporțională cu matricea unitate  $\mathbf{H} = h^2 \mathbf{I}$ , cu avantajul de a avea același parametru de scară  $h$ , ceea ce conduce la un estimator de forma:

$$\hat{p}(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h^d} K\left(\frac{\mathbf{x} - \mathbf{x}_i}{h}\right) \quad (3.32)$$

De obicei se folosește o matrice unică pentru toate eșantioanele, din considerente de complexitate. Se pot folosi în schimb matrici de scară care se adaptează la datele prelucrate. Pentru a se produce o estimare mai exactă a densității este preferabil să alegem o funcție nucleu de bandă îngustă în regiuni cu densitate mare de eșantioane. Contrar, lărgirea benzii permite creșterea preciziei în regiunile cu densitate de eșantioane redusă prin includerea unui număr de eșantioane suficient de mare în estimare. Întâlnim două tipuri de estimatori cu bandă variabilă. Unul care își modifică banda în funcție de locația la care se face estimarea densității denumit estimator de tip balon (balloon estimator):

$$\hat{p}(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n K_{H(\mathbf{x})}(\mathbf{x} - \mathbf{x}_i) \quad (3.33)$$

iar celălalt denumit dependent de eșantion (sample point estimator), își modifică banda pentru fiecare eșantion:

$$\hat{p}(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n K_{H(\mathbf{x}_i)}(\mathbf{x} - \mathbf{x}_i) \quad (3.34)$$

În cazul spațiilor multidimensionale, funcția nucleu poate fi definită în mod admisibil pornind de la o fereastră unidimensională simetrică folosind una din variante:

$$K^P(\mathbf{x}) = \prod_{i=1}^d K_1(x_i) \quad (3.35)$$

sau

$$K^R(\mathbf{x}) = \alpha K_1(\|\mathbf{x}\|) \quad (3.36)$$

unde  $\alpha$  este o constantă de proporționalitate strict pozitivă aleasă astfel încât estimata densității de probabilitate să se integreze la valoarea unitară:

$$\alpha = \frac{1}{\int_{R^d} K(\|\mathbf{x}\|) d\mathbf{x}} \quad (3.37)$$

În prima variantă, funcția nucleu multidimensională se obține ca produs al funcțiilor nucleu unidimensionale. Este și cazul ferestrei hipercubice ce poate fi generată ca produs al ferestrelor unidimensionale rectangulare.

În cel de-al doilea caz funcția nucleu multidimensională se obține rotind fereastra unidimensională în spațiul caracteristicilor, rezultând astfel nuclee cu simetrie radială.

Considerând funcția nucleu simetrică radială:

$$K^R(\mathbf{x}) = c_{k,d} k(\|\mathbf{x}\|^2) \quad (3.38)$$

unde  $c_{k,d}$  de forma

$$c_{k,d} = \frac{\int_{R^d} K^R(\|\mathbf{x}\|) d\mathbf{x}}{\int_{R^d} k(\|\mathbf{x}\|) d\mathbf{x}} = \frac{1}{\int_{R^d} k(\|\mathbf{x}\|) d\mathbf{x}} \quad (3.39)$$

este o constantă selectată astfel încât funcția densitate de probabilitate să se integreze la 1, iar  $k(\mathbf{x})$  este profilul funcției nucleu, definit pentru  $x \geq 0$ .

Estimarea completă a funcției densitate de probabilitate nu este necesară, pentru detecția maximelor acesteia, valoarea funcției densitate de probabilitate nu trebuie cunoscută cu acuratețe deosebită în punctele de maxim, această valoare fiind interesantă doar pentru eliminarea maximelor inconsistente.

Considerând proprietatea ca maximele funcției densitate de probabilitate sunt puncte în care gradientul de densitate este nul, pentru fixarea maximelor se poate construi un algoritm de tip gradient ascendent.

Folosind nucleul cu simetrie radială definit de ecuația (3.38), estimăm gradientul funcției densitate de probabilitate în mod direct, pe baza eșantioanelor disponibile, prin rescrierea ecuației (3.32):

$$\hat{p}(\mathbf{x}) = \frac{c_{k,d}}{nh^d} \sum_{i=1}^n k\left(\left\|\frac{\mathbf{x} - \mathbf{x}_i}{h}\right\|^2\right) \quad (3.40)$$

Estimata gradientului funcției densitate de probabilitate reiese din (3.40), folosind proprietatea de liniaritate a gradientului:

$$\hat{\nabla} p_{h,K}(\mathbf{x}) \equiv \nabla \hat{p}_{h,K}(\mathbf{x}) = \frac{2c_{k,d}}{nh^{d+2}} \sum_{i=1}^n (\mathbf{x} - \mathbf{x}_i) k'\left(\left\|\frac{\mathbf{x} - \mathbf{x}_i}{h}\right\|^2\right) \quad (3.41)$$

Definim funcția nucleu G:

$$G(\mathbf{x}) = c_{g,d} g(\|\mathbf{x}\|^2) \quad (3.42)$$

unde

$$g(x) = -k'(x) = -\frac{dk(x)}{dx} \quad (3.43)$$

este profilul corespunzător nucleului, iar  $c_{g,d}$  este o constantă de normalizare.

Nucleul  $K(\mathbf{x})$  este numit nucleul umbră a lui  $G(\mathbf{x})$ . Așadar, nucleul Epanechnikov este „umbră” nucleului uniform în fereastră. Dacă până acum estimata densității a fost definită cu nucleul  $K(\mathbf{x})$ , algoritmul mean shift folosește nucleul  $G(\mathbf{x})$ . Inserând în ecuația (3.41) pe  $g(x)$  se obține:



$$\begin{aligned}\hat{V}p_{h,K}(\mathbf{x}) &= \frac{2c_{k,d}}{nh^{d+2}} \sum_{i=1}^n (\mathbf{x}_i - \mathbf{x}) g\left(\left\|\frac{\mathbf{x} - \mathbf{x}_i}{h}\right\|^2\right) \\ &= \frac{2c_{k,d}}{nh^{d+2}} \left[ \sum_{i=1}^n g\left(\left\|\frac{\mathbf{x} - \mathbf{x}_i}{h}\right\|^2\right) \right] \left[ \frac{\sum_{i=1}^n \mathbf{x}_i g\left(\left\|\frac{\mathbf{x} - \mathbf{x}_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{\mathbf{x} - \mathbf{x}_i}{h}\right\|^2\right)} \right] - \mathbf{x}\end{aligned}\quad (3.44)$$

Din ecuația (3.44) se observă că primul termen este estimata densității în  $\mathbf{x}$  folosind funcția nucleu G:

$$\hat{p}_{h,G}(\mathbf{x}) = \frac{c_{g,d}}{nh^d} \sum_{i=1}^n g\left(\left\|\frac{\mathbf{x} - \mathbf{x}_i}{h}\right\|^2\right) \quad (3.45)$$

Cel de-al doilea termen al ecuației (3.44) este vectorul mean shift:

$$\mathbf{m}_{h,G}(\mathbf{x}) = \frac{\sum_{i=1}^n \mathbf{x}_i g\left(\left\|\frac{\mathbf{x} - \mathbf{x}_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{\mathbf{x} - \mathbf{x}_i}{h}\right\|^2\right)} - \mathbf{x} \quad (3.46)$$

adică diferența dintre  $\mathbf{x}$ , centrul ferestrei, și media ponderată folosind nucleul  $G(\mathbf{x})$ . Estimata gradientului funcției densitate de probabilitate raportată la scara  $h$ , cu nucleul  $K(\mathbf{x})$ , folosind ecuațiile (3.45) și (3.46), se poate scrie:

$$\hat{V}p_{h,K}(\mathbf{x}) = \hat{p}_{h,G}(\mathbf{x}) \frac{2c_{k,d}}{h^2 c_{g,d}} \mathbf{m}_{h,G}(\mathbf{x}) \quad (3.47)$$

Vectorul mean shift se mai poate scrie și sub forma:

$$\mathbf{m}_{h,G}(\mathbf{x}) = \frac{1}{2} h^2 c \frac{\hat{V}p_{h,K}(\mathbf{x})}{\hat{p}_{h,G}(\mathbf{x})} \quad (3.48)$$

În formula (3.48) ni se indică faptul că, la o locație  $\mathbf{x}$ , vectorul mean shift estimat cu nucleul G este proporțional cu estimata gradientului densității cu funcția nucleu K și invers proporțională cu estimata densității pentru locația  $\mathbf{x}$ , obținută cu funcția

nucleu  $G$ . Prin urmare vectorul mean shift indică direcția cu cea mai rapidă creștere a densității. Fiind aliniat cu estimata de gradient local poate defini o cale spre un punct staționar al densității estimate.

Pașii principali ai algoritmului mean shift sunt:

- calculul vectorului mean shift
- translația cu acest vector a centrului ferestrei
- repetarea pașilor anteriori până la convergență unde gradientul are valoarea zero [24].

## 4. EVALUAREA ASISTATĂ DE CALCULATOR A IMAGINILOR ULTRASONOGRAFICE CU STEATOZĂ

Steatoza, sau boala ficatului gras, este caracterizată de acumularea de țesut gras în ficat. Principalele cauze ale apariției maladiei sunt o regresie în funcționarea metabolismului hepatic, alcoolismul, diabetul și hepatita. Această maladie nu dezvoltă în cele mai multe cazuri nici un fel de simptomatologie. Din această cauză boala este descoperită aleator, la investigarea altor maladii abdominale sau în investigații de rutină. Este necesar ca steatoza să fie descoperită într-un stadiu incipient datorită complicațiilor ce pot apare ulterior. În timpul tratamentului este importantă monitorizarea stadiului evolutiv al maladiei.

### 4.1. Considerații generale

Ultrasonografia este o metodă de imagistică medicală care folosește undele sonore pentru a crea o imagine a ficatului. În capitolul de față vorbim despre ultrasonografie ca metodă folosită în a identifica steatoza hepatică.

Steatoza hepatică este o boală a ficatului caracterizată prin acumulare de grăsimi în celulele hepatice. De obicei trigliceridele sunt cele care se regăsesc în hepatocite. Această afecțiune se poate manifesta temporar sau pe termen lung, nu este dureroasă și poate fi asimptomatică o lungă perioadă de timp. „Ficatul gras” sau „ficat mărit” sunt termenii uzuali folosiți de medici în raport cu pacienții referitor la steatoză. Steatoza este cea mai frecventă patologie hepatică, cu incidență mai mare în țările industrializate, însă ea se manifestă la nivel global.

Factori ce determină steatoza hepatică sunt alcoolismul cronic, obezitatea, diabetul zaharat, alimentație cu o concentrație mare de grăsimi. În funcție de consumul de alcool se pot întâlni două variante ale steatozei: steatoza hepatică alcoolică și steatoza hepatică non-alcoolică (NAFLD – Nonalcoholic fatty liver disease)[25][26][27]. Tot aici avem forme mai severe cum ar fi steatohepatita alcoolică și steatohepatita non-alcoolică.

Boala nu are simptome, cei mai mulți pacienți sunt diagnosticați întâmplător, cu ocazia unui examen ultrasonografic abdominal, a unor analize de sânge de rutină sau în cadrul unui consult medical solicitat pentru alte afecțiuni. Deoarece steatoza hepatică este o afecțiune silențioasă, simptomele manifestându-se abia în stadiile tardive, diagnosticarea survine în urma realizării unor teste medicale de rutină, de exemplu hipercolesterolemia, teste sanguine.

În fazele avansate, simptomele bolii ar fi stări de greutate, insuficiență hepatică, acumulare de lichid în cavitatea abdominală, hemoragie gastrointestinală, oboseală, scăderea poftei de mâncare, balonări abdominale, pierderi în greutate.

Tratamentul în cazul steatozei hepatice este recomandat în funcție de cauze. Dacă nu a condus la apariția unor complicații, boala nu necesită un tratament medicamentos, medicul fiind cel în măsură să recomande un tratament hepatoprotector.

Pentru tratarea bolii sunt recomandate reducerea consumului de grăsimi, alcool, reducerea gradului de sedentarism care să conducă în timp la pierderea în greutate în situațiile în care vorbim de pacienți obezi. Este o boală reversibilă, dacă este diagnosticată și tratată la timp.

Ultrasonografia este o metodă utilizată la detecția și monitorizarea steatozei. Deasemenea aceasta are un cost redus comparativ cu alte metode imagistice. Un avantaj semnificativ este acela că este o metodă non-invazivă deci ultrasonografia are un rol important în imagistica medicală. Cea mai precisă metodă pentru diagnosticarea steatozei este biopsia hepatică, dar aceasta este o soluție invazivă. Unii pacienți au nevoie de supraveghere medicală după efectuarea biopsiei. De asemenea în urma efectuării procedurii pot apare complicații medicale. Prin urmare, biopsia ficatului este de obicei utilizată atunci când metodele neinvazive nu reușesc să ofere un diagnostic clar.

Evaluarea vizuală umană a imaginilor ultrasonografice prezintă un caracter subiectiv și nu poate oferi un grad ridicat de reproductibilitate. Pentru a crește eficiența analizei imaginilor ultrasonografice se pot aplica diferite metode din vederea artificială. Aceste metode pot pleca de la modificarea valorilor de intensitate și până la clasificarea automată (CAD – diagnoza asistată de calculator). Diagnoza cu ajutorul calculatorului consideră rezultatele date de metodele din vederea artificială ca o opinie secundă în evaluarea vizuală.

Sistemele de diagnosticare cu ajutorul calculatorului cunosc o popularitate din ce în ce mai mare în domeniul medical [28]. În analiza ultrasonografiei hepatice aceste sisteme sunt tot mai răspândite [29].

## 4.2. Stadiu actual

Detecția într-o fază primară a steatozei hepatice este importantă, cât și monitorizarea evoluției maladiei, adică regresia sau progresia acesteia, are un rol esențial. Ultrasonografia este o metodă cu un cost redus, comparativ cu alte tehnici din imagistica medicală, utilizată cu succes în depistarea și monitorizarea evoluției acestei maladii. Pentru steatoza hepatică cea mai eficientă metodă de determinare și evaluare o reprezintă biopsia. Însă biopsia este o metodă invazivă, dat fiind că o mostră de țesut hepatic este prelevată în scopul diagnosticării. Efectuarea acesteia cât și reproducerea ei este neplăcută pentru pacient.

Alt dezavantaj al biopsiei este faptul că rezultatele obținute pot fi afectate de erori de eșantionare precum și de variabilitatea interobservator [30]. Utilizarea biopsiei hepatice este de obicei recomandată în situația în care nu se poate stabili un diagnostic precis cu metode neinvazive. Tehnici avansate din imagistica biomedicală, precum tomografia computerizată, sau imagistica prin rezonanță magnetică au fost utilizate în identificarea și monitorizarea steatozei. Folosind tomografia computerizată s-au obținut valori de 82% pentru sensibilitate și 100% pentru specificitate în evaluarea steatozei [31]. Imagistica pe bază de rezonanță magnetică este superioară tomografiei computerizate la identificarea și cuantificarea maladiei, conform studiului din Bohte et al. [32].

Ultrasonografia se pretează a fi utilizată în monitorizarea steatozei hepatice în perioada post diagnosticare, deoarece această metodă prezintă un caracter non-invaziv.

Evaluarea maladiei nu este ușor de îndeplinit, deoarece percepția vizuală umană a intensității este diferită.

Prezența concomitent cu steatoza a altor maladii hepatice produce rezultate diferite ale ultrasonografiei, datorită modificărilor în structura hepatică. Datorită acestui aspect rezultatele studiilor referitoare la diagnosticarea și evaluarea severității steatozei hepatice, variază în literatură.

În [33], media valorilor de consens pentru clasificarea interobservator și intraobservator este de 72 și 76 de procente cu privire la prezența steatozei. Tot în acest studiu, pentru evaluarea gradului de severitate al steatozei, s-a raportat un consens interobservator pentru prima evaluare de 47%-59% și respectiv un consens interobservator de 59%-64%. În ceea ce privește consensul intraobservator pentru evaluarea severității acesta a fost între 55% și 68%.

Studii referitoare la diagnosticarea și evaluarea severității steatozei cu ajutorul calculatorului și a imaginilor ultrasonografice sunt prezentate în [34],[35],[36].

Ficatul steatozic manifestă hiperecogenitate în imaginile medicale ultrasonografice. Aceasta este o caracteristică vizuală esențială ce este utilizată de medici specialiști la evaluarea gradului de severitate a maladiei. În sistemele de diagnosticare folosind inteligența artificială o problemă esențială este alegerea caracteristicilor raportat la scopul propus, astfel încât acestea să prezinte eficiență maximă în clasificare. În diagnosticarea medicală a steatozei, este utilă evaluarea vizuală a hiperecogenității ficatului în imagini ultrasonografice, în raport cu parenchimul rinichiului drept. Un parametru important pentru clasificare este atenuarea posterioară [37].

Caracteristici de textură extrase din imaginile ultrasonografice au fost folosite de mai mulți autori [35],[37]. În [37], s-a realizat un studiu referitor la utilitatea atenuării posterioare și a caracteristicilor de textură de ordinul unu în evaluarea gradului de severitate a steatozei în cazul pacienților infectați cu virusul hepatitei C cronice. Atenuarea este evaluată aici prin utilizarea regresiei liniare folosind aproximarea „least-squares” (Metoda celor mai mici pătrate), soluție non-robustă. Descriptorii de textură extrași au fost media, deviația standard și parametrul de skewness.

### **4.3. Evaluarea automată a steatozei folosind parametrii extrași cu metode de estimare robuste și clasificatoare Random Forests**

Evaluarea automată a steatozei folosind parametrii extrași cu metode robuste și clasificatoare Random Forests au fost studiate de către doctorand în lucrările [38] și [39]. În capitolul 4.3 este prezentată partea teoretică propusă pentru evaluarea automată a steatozei din studiile indicate mai sus.

Estimarea cu acuratețe a valorilor unor caracteristici de interes extrase din imagini este un pas important pentru stabilirea obiectivă a gradului de severitate a afecțiunilor în ultrasonografia abdominală, în general și în evaluarea steatozei, în particular. Datele ce se utilizează în estimarea caracteristicilor se extrag, de regulă, în interiorul unor regiuni de interes. În practică, regiunile de interes sunt delimitate interactiv, datorită faptului că metodele de segmentare autonomă nu asigură întotdeauna funcționalitatea necesară, în condițiile diversității imaginilor ultrasonografice. Diversitatea este datorată în principal variabilității anatomice existente, pe de o parte, și a variabilității direcției 3D de aplicare a sondei, pe de

altă parte. Totodată, din considerente de timp și adesea absența unui logicial de suport avansat, regiunile de interes selectate au forme simple, de tip rectangular, circular sau elipsoidal. Asemenea regiuni, deși asigură adesea acuratețea necesară, pot conține, pe lângă structura anatomică de interes pentru evaluarea cantitativă dorită și elemente ce sunt irelevante, dar care influențează nedorit rezultatele evaluării. În limbaj tehnic, datele supuse analizei pot fi contaminate, cu un număr mai mare sau mai mic, de eșantioane deviate, ce nu aparțin modelului căutat. Efectul erorilor produse de asemenea eșantioane poate fi diminuat semnificativ prin utilizarea unor tehnici de estimare robuste, o practică din ce în ce mai frecvent utilizată în filtrarea, segmentarea și urmărirea obiectelor de interes în imagini. Cu toate acestea, aceste tehnici nu au fost utilizate consecvent în analiza asistată de calculator a imaginilor de ultrasonografie gastrointestinală. Capitolul prezent este dedicat lucrărilor realizate în cadrul tezei, în vederea explorării utilității unor tehnici de estimare robustă asupra rezultatelor analizei și a diagnosticului asistat de calculator a imaginilor de ultrasonografie gastrointestinală.

#### 4.3.1. Caracterizarea atenuării posterioare folosind două pante

Pe baza metodelor de evaluare medicală, am considerat următoarele caracteristici de imagine: atenuarea posterioară minimă, atenuarea posterioară maximă, minimumul robust obținut pentru regiune, maximumul robust obținut pentru regiune, mediana regiunii din parenchimul renal, mediana regiunii din parenchimul hepatic.

Parenchimul renal nu prezintă steatoză și este prezent în vecinătatea țesutului hepatic ceea ce îi demonstrează utilitatea în evaluarea vizuală. Este de așteptat ca, măsurarea acestor parametrii din imaginile ultrasonografice să fie afectată de zgomot de tip „speckle” inerent în investigațiile de acest tip, precum și de artefacte de natură anatomică precum vase sanguine, țesut gras aflat sub dermă, diafragmă și altele. În ideea de a depăși aceste impedimente, pentru extragerea parametrilor am utilizat metode de estimare robustă. Inițial am selectat în mod interactiv regiunea de interes (RI) în imagine. Aceasta este ilustrată în figura 4.1. Se generează curba profilului (figura 4.2) din RI prin medierea imaginii în lungul unei linii pe baza următoarei formule:

$$C(k) = \sum_{j \in RI} I(j, k) / \sum_{j \in RI} 1 \quad (4.1)$$

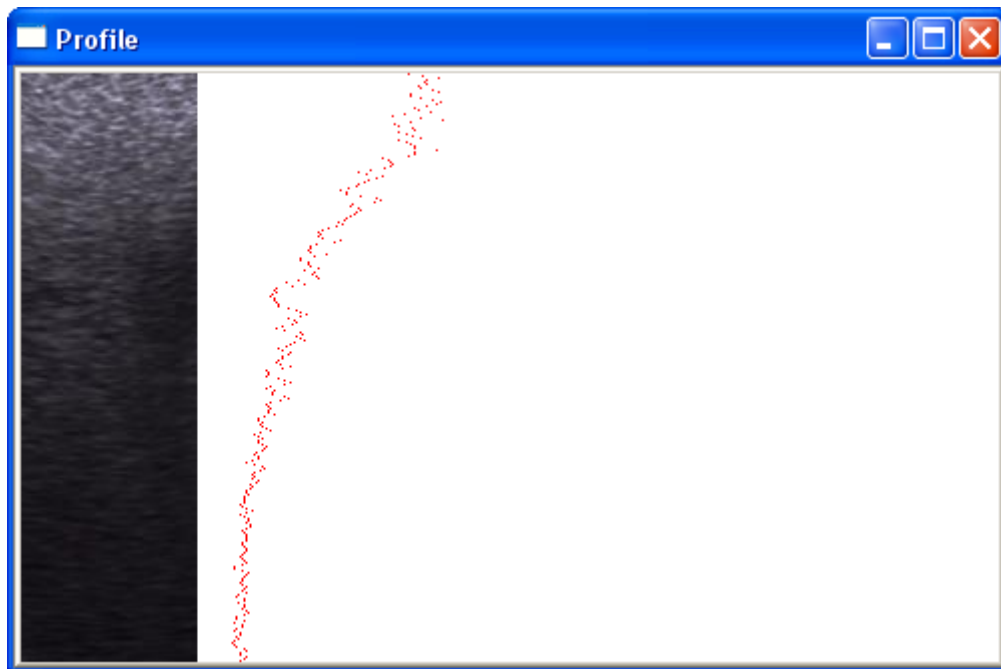
Din figura 4.2 se poate observa faptul că profilul prezintă în continuare neregularități. Pentru a rezolva acest aspect este utilizată regresia liniară robustă. Profilul de luminozitate  $C(k)$  prezintă și neliniaritate astfel că nu este sigur dacă folosirea unei singure drepte de regresie poate defini cu acuratețe curba generată pentru a nu pierde din informațiile utile în evaluarea maladiei.

Pentru a remedia acest lucru se vor efectua două operații de regresie, una pentru 33 de procente din partea superioară a profilului din regiunea de interes și una pentru partea inferioară ce conține restul din regiunea de interes. Din cele două regresii se calculează doi coeficienți ai atenuării posterioare și valorile de minim și maxim robuste. Utilitatea parametrilor propuși este demonstrată de clasificatorul

Random Forests ce folosește un mecanism intrinsec de selecție a parametrilor specifici în evaluarea maladiei.



**Fig. 4.1** Selecție interactivă a regiunii de interes



**Fig. 4.2** Profil generat automat din zona selectată

Asemenea algoritmului RANSAC [12], se definesc seturi minimale de date necesare pentru generarea unei soluții. Setul minimal este preferat deoarece reduce la minim șansa de a conține cel puțin un eșantion deviat, respectiv de a genera o soluție afectată de o eroare mare. Deoarece o dreaptă este univoc definită de două puncte suport, setul minimal de date este constituit dintr-o pereche de puncte ale curbei profil,  $C(k)$ . Soluția constă în perechea de parametri,  $(m, n)$ , ce definesc o dreaptă de forma:

$$y = mx + n \quad (4.2)$$

Coordonata  $y$  corespunde indexului de linie,  $k$ , al imaginii profilului, în timp ce coordonata  $x$  corespunde valorii medii de gri a liniei, respectiv  $C(k)$ . În contrast cu varianta de bază a algoritmului RANSAC, în aplicația curentă nu există argumente consistente pentru a se recurge la o selecție aleatoare a punctelor suport. De asemenea, este lipsită de interes utilizarea tuturor perechilor de puncte posibile. Având în vedere faptul că datele de pe curbă sunt ordonate pe una din cele două coordonate ale spațiului datelor, am optat pentru generarea tuturor perechilor de puncte ce prezintă pe direcția  $y$  un decalaj constant,  $\theta$ . O pereche de puncte,  $(x_k, y_k)$ ,  $(x_k^\theta, y_k^\theta)$  este definită de ecuațiile:



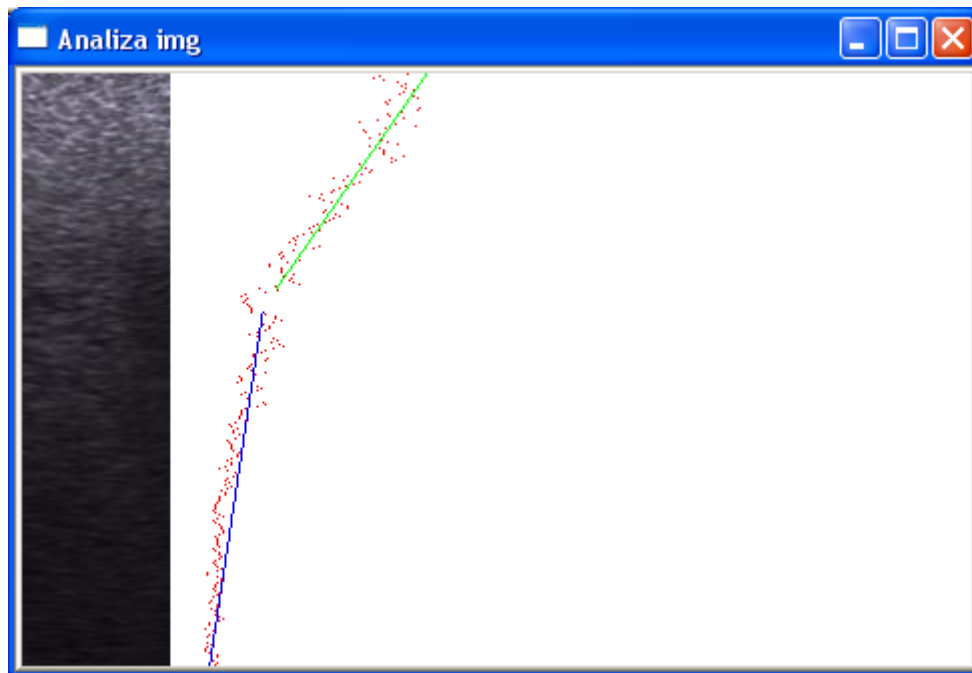
$$\begin{aligned}y_k &= k \\x_k &= C(k) \\y_k^\theta &= k + \theta \\x_k^\theta &= C(k + \theta)\end{aligned}\tag{4.3}$$

Soluțiile candidate de forma  $(m_k, n_k)$  se determină introducând coordonatele calculate mai sus în ecuația (4.2). Pentru o curbă ce conține N puncte, rezultă un număr de  $N-\theta$  soluții. Valoarea parametrului de decalaj se alege prin compromis între două cerințe contradictorii: număr mare de soluții și efect redus al cuantizării coordonatelor. Un decalaj redus permite generarea unui număr de soluții mai mare, apropiat de N, dar introduce erori de cuantizare mai mari. În cazul cel mai defavorabil, pentru  $\theta = 1$ , rezultă o cuantizare a pantelor soluțiilor individuale cu 45 de grade. Limitarea, desigur este mai puțin severă pentru soluția finală.

Spre deosebire de problemele de aliniere a imaginilor pe baza corespondențelor ipotetice între punctele perechilor de imagini, unde există un grad de incertitudine mult mai mare, putem presupune că majoritatea perechilor de puncte ale curbei profil este necontaminată cu erori aberante. Asemenea puncte pot fi generate de prezența unor vase sanguine mari sau a unor leziuni, cu dimensiuni ce nu vor depăși jumătate din suprafața regiunii de interes. Exploatăm această realitate și extragem soluțiile pentru cei doi parametri folosind estimatorul median:

$$\begin{aligned}\hat{m} &= \arg \min_k |\hat{m} - m_k| \\ \hat{n} &= \arg \min_k |\hat{n} - n_k|\end{aligned}\tag{4.4}$$

În figura 4.3 sunt redate dreptele de regresie,  $C_{sus}(k)$  definită de culoarea verde pentru partea superioară a RI și  $C_{jos}(k)$  reprezentată prin culoarea albastră pentru restul RI, obținute pentru profilul din figura 4.2. În faza de analiză a imaginilor se definesc parametrii de clasificare: maximul robust ( $k_{sus}$ ), minimul robust ( $k_{min}$ ), atenuarea maximă ( $m_{sus}$ ), atenuarea minimă ( $m_{jos}$ ), mediana unei RI din ficat ( $Medf$ ) și mediana RI din rinichi ( $Medr$ ).




**Fig. 4.3** Regresie robustă

În figura 4.4 se observă modul de selecție al regiunilor de interes din ficat și respectiv rinichi din aceeași imagine ultrasonografică în vederea generării medianelor.

În [37], s-a realizat o comparație între utilitatea parametrului de atenuare și parametrii de textură extrași din imagini ultrasonografice standard în vederea evaluării automate a gradului de severitate a steatozei hepatice. Pacienții incluși în acest studiu sufereau și de alte probleme hepatice pe lângă „ficat gras”. Din acest studiu reiese că doar parametrul de textură reprezentat de medie se corelează semnificativ cu steatoza. Conform acestora parametrul de atenuare este mai eficient în evaluarea gradelor de severitate a steatozei în comparație cu media ce reprezintă un descriptor de textură de ordinul unu.

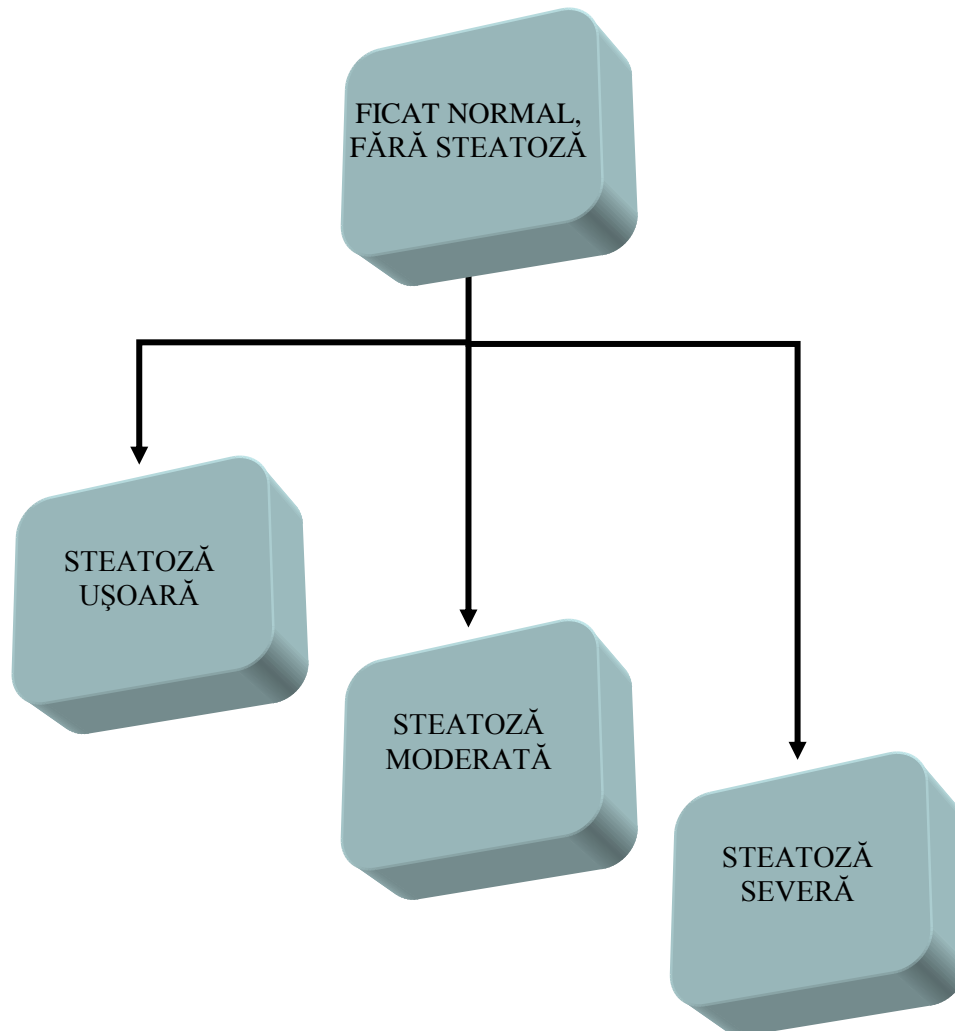
În [40] se realizează o comparație în vederea clasificării automate a severității steatozei din imagini ultrasonografice, între coeficientul de atenuare și parametrii de textură derivați din matricea GLCM (Grey Level Co-occurrence Matrix). În acest studiu, în urma comparației, se observă rezultate mai bune prin aplicarea coeficientului de atenuare. În [41] s-a utilizat în clasificarea steatozei parenchimul rinichiului drept.



**Fig. 4.4** Selecție în timp real a RI în rinichi (dreptunghi roșu) și RI din ficat (dreptunghi verde)


### **4.3.2. Clasificare**

Pe baza evaluărilor medicale, steatoza se poate diferenția în patru stadii evolutive. Severitatea maladiei este cuantificată în ficat normal, steatoză ușoară, moderată și steatoză severă. Cele patru stadii de severitate se pot observa în figura 4.5.




**Fig. 4.5** Grade de severitate pentru steatoză în ficat


În figura 4.6 sunt redată exemple pentru cele patru stadii de evoluție în imagini medicale ultrasonografice.




(a)



(b)



(c)



(d)

**Fig. 4.6** Stadii de severitate pentru steatoză: (a) ficat normal, (b) steatoză ușoară, (c) steatoză moderată, (d) steatoză severă

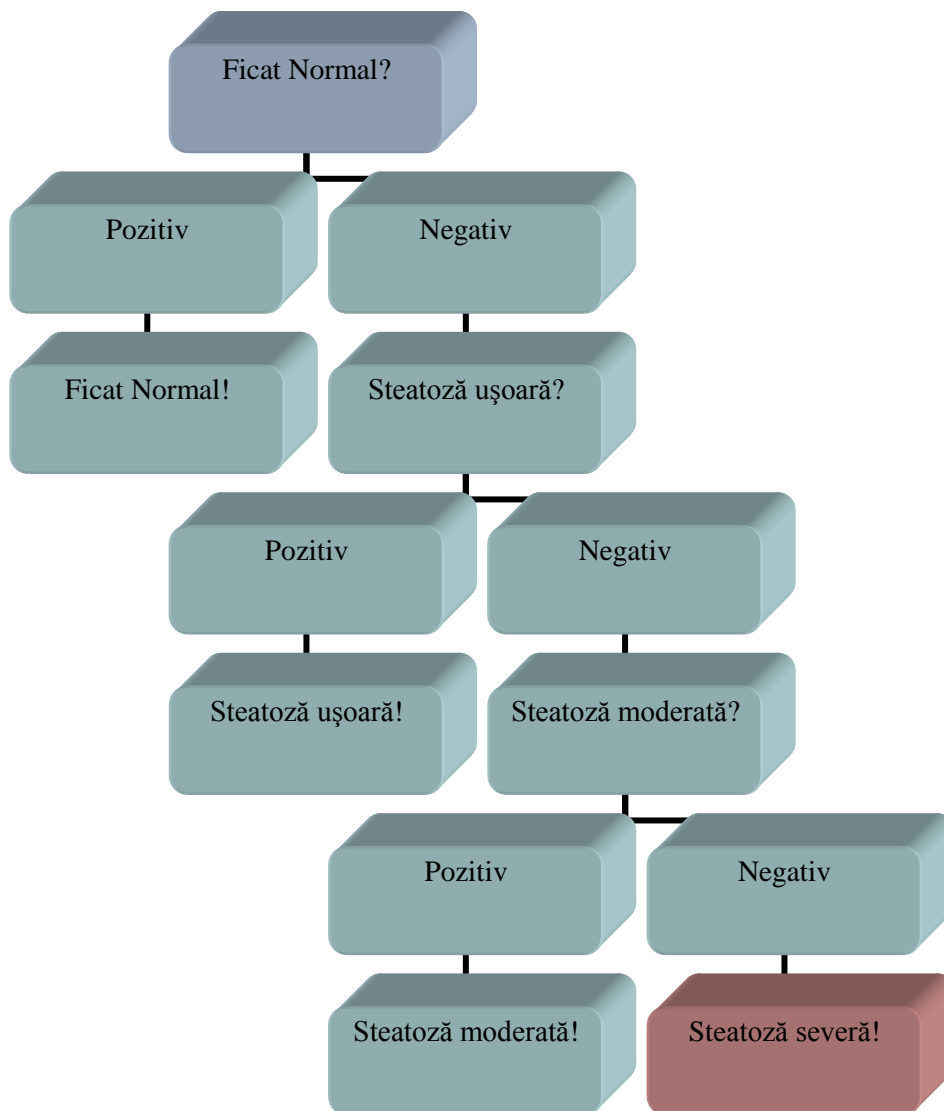
La clasificarea steatozei se folosește Random Forests [42], acesta nefiind utilizat până acum în clasificarea automată a gradelor de severitate a steatozei hepatice din imagini medicale ultrasonografice. Random Forests este mai bun decât



clasificatoarele tradiționale, fiind un clasificator de tipul „ensemble classifiers”. Acesta este un clasificator de actualitate în inteligența artificială, ce emulează bine diagnoza efectuată de medici. În [34], la evaluarea automată a steatozei hepatice din imagini ultrasonografice s-a folosit SVM, acuratețea clasificării cu setul complet de caracteristici fiind de 87.5%, iar cea mai bună valoare pentru acuratețe la clasificarea cu fiecare caracteristică în parte a fost de 85.19%, valori obținute pentru datele de test. SVM a fost utilizat și în [43] pentru clasificarea gradelor de evoluție a maladiei.

Se consideră patru clase corespunzătoare stadiilor de severitate enumerate. Pentru evaluarea automată se folosesc două versiuni ale clasificatorului Random Forests. Prima versiune utilizează toate clasele în procesul de clasificare, iar cea de-a doua folosește dihotomii succesive conform figurii 4.6: setul de date ce conține ficat normal și restul claselor ce cuprind steatoza hepatică, steatoza ușoară versus steatoza moderată și severă, iar pentru nivelul trei, steatoză moderată versus steatoză severă. Granița de separație între clase poate fi modelată matematic teoretic mai ușor pentru clasificatorul cu dihotomii succesive, ceea ce poate genera un acord superior în evaluarea automată.

Parametrul  $\theta$  utilizat în ecuația (4.2) este setat cu valoarea 20 în cadrul experimentelor efectuate. Referința în clasificare este dată de rezultatele evaluării medicale, realizate de cei mai buni medici în domeniul gastroenterologiei.



**Fig. 4.7** Clasificarea steatozei pe bază de dihotomii succesive

### 4.3.3. Rezultate experimentale

În acest subcapitol sunt prezentate rezultatele experimentale din articolele [38] și [39]. Datele folosite în etapa de învățare a clasificatorului au fost selectate folosind metoda cross-validation. Procedura de clasificare a fost reluată de 20 de ori folosindu-se de fiecare dată un set de antrenament diferit luând în considerare 80% din date.

Pentru cea de-a doua versiune a clasificatorului la fiecare dihotomie s-au efectuat 20 de experimente. În urma experimentelor efectuate în cazul primului tip de clasificator, rezultatele obținute au fost în acord cu cele medicale în proporție de 82,2%. Folosind clasificatorul Random Forests cu dihotomii succesive procentul obținut a fost de 85,86%. Acest rezultat ne-a confirmat presupunerea noastră, știind de la început că liniile de separație dintre clase au o formă mai simplă.

În tabelul 1 și 2 sunt generate matricile de confuzie pentru clasificatorul cu toate clasele și respectiv, clasificatorul pe bază de dihotomii succesive.

**Tabel 1** Matricea de confuzie pentru clasificatorul Random Forests cu întregul set de date [39]

		Clasificare Automată			
		Ficat Normal	Steatoză Ușoară	Steatoză Moderată	Steatoză Severă
Evaluare Medicală	Ficat Normal	4	1		
	Steatoză Ușoară		43	1	
	Steatoză Moderată		1	14	
	Steatoză Severă			4	0

Conform tabelului folosind clasificatorul Random Forests cu toate clasele se poate observa că eroarea maximă este de o clasă, neîntâlnindu-se situația saltului a două clase (ex. ficat normal – steatoză moderată).

**Tabel 2** Matricea de confuzie pentru clasificatorul Random Forests cu dihotomii succesive [39]

		Clasificare Automată			
		Ficat Normal	Steatoza Ușoară	Steatoză Moderată	Steatoză Severă
Evaluare Medicală	Ficat Normal	4	1		
	Steatoză Ușoară		43	1	
	Steatoză Moderată		1	14	
	Steatoză Severă			3	1

Același lucru îl confirmă și datele din tabelul 2 cu o completare ce ne arată o diferențiere mai corectă între steatoza moderată și steatoza severă.

În urma experimentelor efectuate rezultă importanța variabilelor de clasificare, lucru prezentat în tabelul 3.

**Tabel 3** Importanța parametrilor utilizați în clasificare folosind cele două variante pentru clasificatorul Random Forests [39]

Nivel de importanță [%]	Toate clasele	Dihotomii succesive
Atenuarea posterioară maximă	12.71	8.47
Maximul robust	21.56	21.05
Atenuarea posterioară minimă	16.60	17.42
Minimul robust	13.62	10.78
Mediana - hepatic RI	22.70	28.91
Mediana - rinichi RI	12.78	13.37

Din tabelul 3 se poate observa importanța tuturor parametrilor folosiți în clasificarea automată a steatozei hepatice. Atenuarea posterioară globală oferă o caracterizare bună a ficatului în ceea ce privește clasificarea, ceea ce justifică folosirea a două drepte de regresie. Cu toate acestea ponderea cea mai mare o au mediana din regiunea de interes hepatică și maximul robust.

#### 4.4. Studiu comparativ folosind două clasificatoare, Random Forests și SVM

În subcapitolul 4.3. am prezentat o comparație între două variante ale clasificatorului Random Forests, unul ce utilizează toate cele patru clase și unul ce utilizează dihotomii succesive. În capitolul prezent ne referim la un studiu comparativ folosind două clasificatoare, unul fiind Random Forests, iar celălalt SVM (Support Vector Machines) [44]. Din cele două clasificatoare Random Forests folosite în studiul anterior, mai bun a fost cel care utilizează dihotomii succesive. Atât Random Forests, cât și SVM sunt considerate printre cele mai bune clasificatoare din domeniul inteligenței artificiale. În capitolul 4.4. vom compara clasificatorul Random Forests cu SVM, studiul și experimentele prezentate în acest capitol au fost publicate în articolul [45], apărut la Cluj-Napoca în jurnalul „Medical Ultrasonography”, Vol. 15, Numărul 3, paginile 184-190, 2013, ISSN 1844-4172.

Clasificatorul SVM utilizat pentru motive de comparație în această lucrare este un clasificator binar. SVM realizează o transpunere a datelor în două clase prin construcția de hiperplane de separație. Este selectat hiperplanul care desparte datele la o cât mai mare distanță relativ la vectorii suport a celor două clase. Pentru a avea o eficiență ridicată în cazul datelor ce nu sunt liniar separabile, vectorii de date se transpun pe un spațiu mai mare din punct de vedere dimensional, prin așa numitul „kernel trick”.

Folosind date de antrenament dintr-un spațiu cu dimensiuni reduse, clasificatoarele SVM au capacitatea de a generaliza cu performanțe bune. Principala măsură a performanței și comparației este precizia.

La clasificare s-a utilizat un set extins de caracteristici. Acesta este format din atenuarea posterioară minimă, atenuarea posterioară maximă, minimul robust, maximul robust, extrase folosind metoda robustă propusă în capitolul 4.3, mediana nivelurilor de gri a regiunii de interes hepatice, mediana nivelurilor de gri pentru regiunea selectată în parenchim renal, la care se adaugă dispersia, skewness și kurtosis extrase din histograma regiunii de interes.

Se poate defini acuratețea clasificatorului ( $AC$ ), astfel:

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.5)$$

unde  $TP$  este numărul cazurilor adevărate pozitive,  $TN$  numărul cazurilor adevărate negative,  $FP$  totalul cazurilor false clasificate ca pozitive, iar  $FN$  numărul de cazuri false negative.

Probabilitatea erorii la clasificarea cu dihotomii succesive este:

$$P_{ed} = P_1 P_{e1} + P_2 (P_{e1} + P_{e2}) + (P_3 + P_4)(P_{e1} + P_{e2} + P_{e3}) \quad (4.6)$$

unde  $P_i$  este probabilitatea apriorică a clasei „ $i$ ” și  $P_{ei}$  sunt probabilitățile de eroare a celor trei clasificatoare binare din figura 4.6.

Relația matematică între probabilitatea de eroare și acuratețe este următoarea:

$$AC = (1 - P_{ed}) \times 100\% \quad (4.7)$$

#### 4.4.1. Experimente

Evaluarea medicală a fost considerată referință pentru comparație. Seturile de date de antrenament au fost obținute prin metoda „cross-validation”. Rezultatele clasificării cu dihotomii succesive pentru Random Forests și SVM sunt prezentate în tabel 4, respectiv tabelul 5.

**Tabel 4** Clasificare cu Support Vector Machines cu dihotomii [45]

Clasificare	Rata de clasificare minimă	Rata de clasificare maximă	Deviația standard	Mediana	Acuratețe
Ficat sănătos versus Steatoză	91.67	91.67	0.0	91.67	60.51
Steatoză ușoară versus Moderată + Severă	70.91	72.73	0.7469	72.73	
Steatoză moderată versus Severă	82.5	82.5	0.0	82.5	

**Tabel 5** Clasificare cu Random Forests cu dihotomii [45]

Clasificare	Rata de clasificare minima	Rata de clasificare maxima	Deviația standard	Mediana	Acuratețe
Ficat sănătos versus Steatoză	95.8	100.0	1.2927	100.0	90.84
Steatoză ușoară versus Moderată + Severă	90.9	100.0	3.1123	100.0	
Steatoză moderată versus Severă	37.5	100.0	23.3941	81.25	

La fel ca și în capitolul 4.3 experimentele au fost repetate de 20 de ori. Din setul de rezultate obținut au fost extrase rata de clasificare maximă, rata de clasificare minimă, mediana și deviația standard, iar pe baza ecuației (4.7) s-a calculat acuratețea.

În tabelul 6 este redată importanța variabilelor de clasificare dată de Random Forests.

**Tabel 6** Importanța variabilelor utilizate în clasificare [45]

Parametru	Importanța[%]
Atenuare posterioară maximă	3.45763
Maximul robust	8.031634
Atenuare posterioară minimă	12.7997
Minimul robust	6.656511
Mediana RI ficat	42.49108
Mediana RI rinichi	4.818146
Dispersia	13.20869
Skewness	3.766459
Kurtosis	4.770152

Din analiza tabelului 6, rezultă că mediana obținută din regiunea de interes hepatică alături de dispersie sunt doi parametri cu importanță ridicată în clasificare.

În continuare se definește setul de caracteristici format cu maximul robust din regiunea de interes aparținătoare ficatului și mediana nivelurilor de gri din regiunea de interes selectată a ficatului. Folosind clasificatoarele SVM și Random Forests pentru setul de parametri selectat s-au obținut rezultatele prezentate în tabelele 7 și respectiv 8.

**Tabel 7** Clasificare cu SVM și dihotomii succesive folosind setul de caracteristici ce include maximul robust din regiunea de interes hepatică și mediana nivelurilor de gri din regiunea de interes a ficatului [45]

Clasificare	Ficat sănătos versus steatoză	Steatoză ușoară versus moderată + severă	Steatoză moderată versus severă
Rata de clasificare minimă	94.17	90.0	85.0
Rata de clasificare maximă	94.17	91.82	85.0
Deviația standard	0.0	0.5343	0.0
Mediana	94.17	90.91	85.0
Acuratețe	81.12		

**Tabel 8** Clasificare cu Random Forests și dihotomii succesive folosind setul de caracteristici ce include maximul robust din regiunea de interes hepatică și mediana nivelurilor de gri din regiunea de interes a ficatului [45]

Clasificare	Ficat sănătos versus steatoză	Steatoză ușoară versus moderată + severă	Steatoză moderată versus severă
Rata de clasificare minimă	91.7	86.4	75.0
Rata de clasificare maximă	100.0	100.0	100.0
Deviația standard	2.8120	4.2442	7.3392
Mediana	93.75	95.5	100.0
Acuratețe	87.10		

Pentru o altă selecție, setul fiind alcătuit din atenuarea posterioară minimă generată cu o metodă robustă și mediana nivelurilor de gri a regiunii de interes a ficatului, se vor obține două seturi de rezultate, prin aplicarea clasificatoarelor SVM și Random Forests, pe care le prezentăm în tabelele 9 și respectiv 10.

**Tabel 9** Parametrii clasificării cu SVM și dihotomii succesive considerând setul de caracteristici ce include atenuarea posterioară minimă generată cu o metodă robustă și mediana nivelurilor de gri a regiunii de interes a ficatului [45]

Clasificare	Ficat sănătos versus steatoză	Steatoză ușoară versus moderată + severă	Steatoză moderată versus severă
Rata de clasificare minimă	95.0	94.55	90.0
Rata de clasificare maximă	95.0	96.36	92.50
Deviația standard	0.0	0.6871	1.1754
Mediana	95.0	95.45	90.0
Acuratețe	87.78		



**Tabel 10** Parametrii clasificării cu Random Forests și dihotomii succesive considerând setul de caracteristici ce include atenuarea posterioară minimă generată cu o metodă robustă și mediana nivelurilor de gri a regiunii de interes a ficatului [45]

Clasificare	Ficat sănătos versus steatoză	Steatoză ușoară versus moderată + severă	Steatoză moderată versus severă
Rata de clasificare minimă	87.5	81.8	87.5
Rata de clasificare maximă	100.0	100.0	100.0
Deviația standard	4.2488	4.5553	6.3802
Mediana	95.8	93.2	100.0
Acuratețe	87.29		

Acuratețea clasificatorului SVM a crescut, de la valoarea de 60.51 cu setul complet de date până la 87.78 pentru setul de caracteristici compus din atenuarea posterioară minimă obținută cu o metodă robustă și mediana nivelurilor de gri din regiunea de interes aparținând ficatului, prin utilizarea selecției caracteristicilor.

Cea mai bună acuratețe a clasificatorului Random Forests având valoarea de 90.84 este obținută folosind întregul set de caracteristici, în timp ce utilizând selecția caracteristicilor, valorile rezultate au fost mai slabe. Utilizând selecția caracteristicilor, clasificatorul SVM prezintă rezultatele cel mai bune. SVM a fost utilizat anterior în studii ce privesc clasificarea steatozei hepatice, de aceea comparația cu Random Forests este utilă.

## 5. EXTRAGEREA OPTIMIZATĂ A CURBELOR INTENSITATE-TIMP ÎN ULTRASONOGRAFIA DE CONTRAST


Un procedeu tot mai des întâlnit la definirea caracteristicilor pentru diagnosticarea automată a leziunilor focale hepatice, folosind agent de contrast, este tehnica de analiză a curbelor intensitate-timp [46]. Aceste curbe de intensitate-timp sunt generate de variația intensității semnalului pe parcursul secvenței video. Investigația imagistică ce folosește ultrasonografia cu substanță de contrast utilizează un agent constituit din microbule pentru intensificarea contrastului imaginilor obținute. Această metodă este tot mai des utilizată în evaluarea medicală a ficatului [2],[47],[48],[49],[50],[51],[52]. Un ghid de recomandări pentru ultrasonografia cu substanță de contrast este prezentat în [53]. Alături de recomandări pentru evaluarea leziunilor hepatice, în acest ghid sunt prezentate sfaturi pentru utilizarea CEUS în investigații ale rinichiului, pancreasului, refluxului vezico-ureteric, traume și circulație cerebrală. Evaluarea medicală a leziunilor hepatice focale se caracterizează prin trei faze:

- faza arterială, (15-30 de secunde)
- faza portală, (30-120 de secunde)
- faza vasculară, (120-300 secunde) [2].


Timpul necesar investigației unui pacient este cu aproximație cinci minute [2]. Substanța de contrast este constituită din microbule cu un grad înalt de ecogenitate ceea ce duce la o creștere a abilității vaselor sanguine de a reflecta ultrasunetele [3]. Microbulele nu au efecte adverse pentru pacienți, fiind eliminate în mod natural prin respirație sau distruse în timpul investigației medicale.

Diagnosticarea leziunilor hepatice focale se bazează pe modificările perfuziei sanguine în țesut și constă în evaluarea unor parametri ai dinamicii perfuziei caracterizați de parametri extrași din curbele intensitate-timp (TIC). Astfel de curbe sunt extrase din secvențele video CEUS din regiunile de interes selectate și utilizate apoi la evaluarea leziunilor focale hepatice în [54], în patologia cardiacă [55] și în patologia reno-urinară [56],[57],[58]. Investigațiile medicale CEUS sunt efectuate de medici specializați în ultrasonografie. Cele mai des întâlnite cazuri de leziuni hepatice focale sunt prezentate în figurile 5.1-5.4.


În momentul începerii investigației specialistul trebuie să fixeze transductorul pe leziune într-o poziție cât mai bună și să înceapă înregistrarea imaginilor imediat după injectarea substanței de contrast. Există și situații în care, în ideea de a evita distrugerea timpurie a microbulilor cauzată de undele ultrasonografice, operatorul induce o mișcare voită a transductorului. În realitate, datorită mișcărilor transductorului și a respirației pacientului în secvența de imagini se manifestă o cantitate semnificativă de mișcare.




**Fig. 5.1** Carcinom hepatocelular



**Fig. 5.2** Hemangiom



**Fig. 5.3** Hiperplazie nodulară focală



**Fig. 5.4** Metastaze hepatice

Setul de date înregistrat este alcătuit din două secvențe de imagini, una obținută prin utilizarea substanței de contrast și una specifică ultrasonografiei standard. Imaginile sunt obținute alternativ la o rată de aproximativ 10 cadre pe secundă și separate printr-un proces de filtrare acustică. Ultrasonografia standard ne prezintă mai clar structurile anatomice, iar ultrasonografia cu substanță de contrast redă informația funcțională. În ambele imagini întâlnim un nivel ridicat de zgomot de tip „speckle”, în comparație cu imaginile redade de CT și MRI. Dată fiind proprietatea microbulilor de a avea dimensiuni mici,  $10\ \mu\text{m}$  și rezoluția finită a transductoarelor, înregistrările imaginilor cu substanță de contrast, conțin un zgomot specific, caracteristic unui întrerupător cu cele două poziții pornit-oprit ce poate fi explicat ca efect de subeșantionare. Acest zgomot alături de mișcarea cauzată de respirația pacientului și deplasarea transductorului prezintă o provocare importantă în prelucrarea imaginilor ultrasonografice cu substanță de contrast. În figura 5.5 este prezentat un model teoretic pentru curba intensitate-timp într-o secvență CEUS și de asemenea sunt definiți câțiva parametri (TA - timp de sosire, TI - timp de creștere, TMI - timp necesar pentru maximă intensificare) ai curbei utili în evaluarea obiectivă a perfuziei sanguine. Parametrii extrași din curba intensitate-timp au un rol important în diagnosticul automat pe baza CEUS, însă aceștia sunt extrem de sensibili la zgomot.

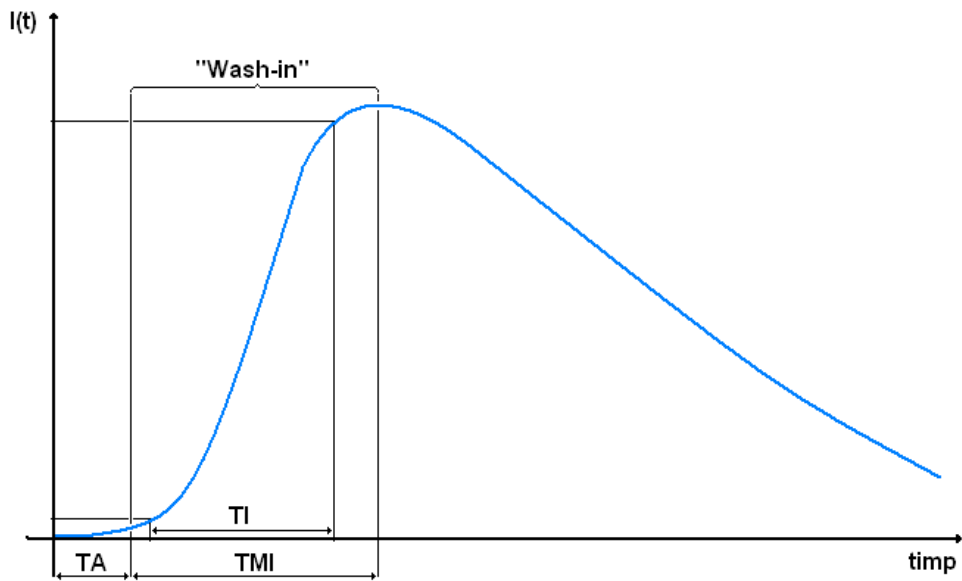


Fig. 5.5 Model teoretic pentru TIC.  $I(t)$  reprezintă intensitatea în RI

Pentru a obține o netezire a acestor curbe se pot utiliza metode de reducere a influenței zgomotului. Contaminarea leziunii hepatice focale, datorită pixelilor adiacenți se poate evita prin utilizarea metodelor de netezire ce conservă muchiile. Zgomotul ce se manifestă în imaginile medicale ultrasonografice este zgomotul de tip speckle. Pentru filtrarea acestui tip de zgomot au fost propuse mai multe soluții. În [59] s-a realizat o aproximare liniară optimală statistică pentru filtrarea zgomotului multiplicativ. În [60] este dezvoltată o tehnică statistică pentru a defini modelul zgomotului, urmată de aplicarea unui algoritm de filtrare a zgomotului bazat pe statistici. Un filtru neliniar cu rezultate excelente în eliminarea zgomotului concomitent cu păstrarea muchiilor a fost propus încă din anul 1983 de către Lee [61]. Ideea de bază a filtrului Lee este de a se media doar pixelii vecini ale căror intensități se găsesc în interiorul unui interval sigma față de pixelul central. Parametrul sigma al filtrului măsoară neomogenitatea locală a imaginii. Filtrul poate fi considerat un precursor al filtrului bilateral. Metode de filtrare ce au la bază filtrul sigma sunt prezentate în [62],[63]. Conform [64], filtrul din [61] are deficiențe la realizarea unei estimății deplasate (biased) și conduce la estomparea muchiilor. Prin urmare acesta este îmbunătățit în [64], unde intervalul sigma este redefinit având în vedere funcțiile densitate de probabilitate a zgomotului speckle și este dezvoltată o tehnică pentru conservarea semnăturii țintei. Un algoritm ușor de implementat în spațiul de date este prezentat în [65]. În [66] este propusă o soluție de filtrare adaptivă prin utilizarea valorilor parametrilor estimate local, rezultând estimate ale erorilor medii pătratice minime în interiorul regiunilor omogene aparținătoare imaginii. Un filtru capabil să se adapteze la statisticile de imagine locale nestaționare în prezența diferitelor forme de zgomot dependent de semnal, este introdus în [67]. În [68], pentru reducerea zgomotului speckle din imagini radar a fost dezvoltat un filtru median adaptiv local. Acesta folosește statistici locale pentru a detecta și înlocui zgomotul cu o mediană locală. În [69] autorul propune doi algoritmi pentru filtrarea zgomotului multiplicativ din imaginile SAR (Synthetic Aperture Radar). În [70] este prezentată o metodă de difuzie anisotropică pentru imagini multiscară, folosind vectorii proprii și valorile proprii ale primei forme fundamentale din metrică, difuzia realizându-se printr-un sistem de ecuații diferențiale cuplat. În [71], este utilizată difuzia anisotropică pentru reducerea zgomotului speckle. Pentru filtrarea zgomotului din imagini SAR în [72] este utilizată modelarea parametrilor wavelet folosind distribuția alfa-stabilă. În imagini ultrasonografice, zgomotul este filtrat utilizând o metodă multiscară bayesiană în [73]. Distribuțiile cu cozi lungi (heavy-tailed) cum este modelul alfa-stabil descriu cu cea mai bună acuratețe statisticile non-Gaussiene conținute în descompunerile sub-bandă a imaginilor ultrasonografice [73]. Filtrări de imagini ultrasonografice folosind transformata wavelet sunt prezentate în [74] și [75]. În lucrarea [76], este propusă o metodă de filtrare a zgomotului din imagini radar în domeniul wavelet ce constă în combinarea transformatei wavelet DT CWT (Dual Tree Complex Wavelet Transform) cu o variantă a filtrului bishrink, iar în [77] la algoritmul de filtrare se folosește transformata DEDWT (Diversity Enhanced Discrete Wavelet Transform). O altă soluție în care se utilizează transformata wavelet hiperanalitică pentru filtrarea imaginilor este prezentată în [78]. În [79] filtrarea se realizează având în considerare spațialitatea și similaritatea fotometrică. Filtrul non-local means [80] folosește un kernel gaussian și atribuie ponderi mai însemnate pixelilor cu vecinătate similară. Pentru filtrare este utilizată o imagine de ghidare în [81]. Autorul propune în [82] o metodă de filtrare prin utilizarea unei scări variable în determinarea maximului densității de probabilitate. Scara definită pe un profil sferic



este monoton descrescătoare cu fiecare iterație a filtrului pentru a se evita setarea algoritmului într-o maximă locală. O metodă de filtrare folosind norme „sparse” și minimizarea unei funcții cost non-pătratice apare prezentată în [83], iar în [84] este folosit un model bayesian pentru adaptarea filtrului non-local means la zgomot speckle. Ecuații diferențiale parțiale sunt aplicate în [85] pentru filtrarea acestui zgomot. Filtrarea spațio-temporală a secvențelor ultrasonografice este propusă în [86]. O metodă ce folosește transformata wavelet și un prag adaptiv este descrisă în [87]. Pentru filtrarea speckle este utilizat un element structurator de forma „cross neighbourhood” în [88], iar în lucrarea [89] filtrarea este obținută folosind „Graph Cuts”.

Prin tehnicile de regresie se poate obține o unealtă puternică pentru generarea de curbe intensitate-timp netede ce se pretează la extragerea dinamică a parametrilor. O tehnică larg raspândită, deseori inclusă în pachetele software dezvoltate de producătorii de aparatură medicală, se bazează pe modelarea datelor la o curbă standard. Modelarea după o exponențială a fazei arteriale a fost utilizată în [54], respectiv [55]. În [90], s-a utilizat un model de distribuție log normală pentru modelarea globală a TIC ce cuprinde atât faza arterială cât și faza venoasă (portală). În timp ce modelarea robustă funcționează eficient și reușește să tolereze date lipsă, în unele aplicații reale curba generată prin această abordare nu este îndeajuns de precisă pentru a genera parametrii necesari [91]. Segmentarea interactivă a imaginii este cea mai precisă metodă pentru segmentarea imaginilor ce compun secvențele CEUS. Acest lucru este însă prea incomod pentru a fi inclus ca un element de rutină pentru medici. Pentru a depăși această problemă a segmentării, în [91], este dezvoltat un software interactiv de înaltă performanță pentru segmentarea și analiza imaginilor. Autorii definesc volume spațio-temporale având dimensiunea de 5x5x3 voxelii în interiorul cărora determină valorile de intensificare. Voxelii ce dezvoltă profile de intensificare similare sunt grupați apoi în cadrul unei proceduri interactive de segmentare. Pentru că imaginile cu intensificarea leziunii conțin niveluri ridicate de zgomot și dimensiunea vecinătății utilizată are valori mici, curbele intensitate-timp sunt generate prin metode de mediere robuste. Anvelopele inferioară și superioară ale TIC sunt definite de medierile primei și celei de-a treia quartile, în timp ce procentul de pixeli cu o intensificare mai mare decât un prag  $k$  au generat un profil TIC ce s-a dovedit a fi cel mai fiabil. Valorile pentru dimensiunea optimă a vecinătății și pragul optim sunt setate interactiv de către operator. Segmentarea automată ar reprezenta un ajutor important pentru medici deoarece reduce volumul de muncă pe partea interactivă, însă aceasta este dificil de implementat pentru imagini CEUS datorită nivelului ridicat de zgomot și a contrastului slab generat de leziunea hepatică focală în stadiu timpuriu de „wash-in” și în stadiu tardiv de „wash-out” a secvenței video. În [92] a fost propusă o metodă de segmentare a imaginii complet automată în vederea identificării leziunilor renale din CEUS.

Pentru a depăși problemele generate de mișcare în imagini se pot utiliza tehnicile de înregistrare. Tehnici de înregistrare utilizate în imagistica medicală ultrasonografică au fost propuse în [93],[94],[95],[96]. Pentru a optimiza tehnica de înregistrare în vederea analizei pereților intestinali, în [97] este utilizat un model Markov pentru câmpuri aleatoare.

### 5.1. Motivație teoretică

Pentru extragerea unor curbe intensitate-timp eficiente din secvențe CEUS este necesar ca metodele de procesare să nu fie afectate de incertitudini generate de zgomot și mișcare. Ideal ar fi ca intensitățile să fie evaluate numai în cadrul leziunii focale. Regiunea de interes se poate alege prin segmentare interactivă sau automată, însă nici una dintre aceste soluții nu elimină toate problemele. Chiar și cu o segmentare foarte bună, zgomotul de tip speckle produce în cadrul regiunii selectate multe valori aberante ce variază cu mult față de valorile corecte. Aceste valori aberante în cazul în care sunt asimetric distribuite, produc erori mari pentru estimatori precum media aritmetică sau media ponderată. Erorile de segmentare și estimarea eronată a mișcării sunt adesea datorate valorilor aberante distribuite asimetric. Metodele robuste pleacă de la premisa că valorile aberante au o influență limitată asupra estimatei, indiferent de cât de deviate sunt de la valoarea reală. Între numeroasele metode de procesare robustă a imaginilor, în cadrul comunității din domeniul „computer vision” au primit o atenție considerabilă aplicațiile algoritmului mean shift [22] în filtrarea imaginilor [23], segmentare [23][98] și tracking [99][100]. Mean shift este o metodă eficientă în a găsi modurile densității de probabilitate din cadrul unui set de date multivariat discret, fără a fi necesară cunoașterea în profunzime a funcției densitate de probabilitate. Algoritmul poate porni cu orice locație din spațiul caracteristicilor, de exemplu acesta se poate inițializa cu un anumit punct ce aparține setului de date. Acesta calculează o medie ponderată în jurul punctului și realizează o deplasare către media ponderată găsită. De la noua locație calculată, procedura este repetată și iterată până la convergență. Pasul cu care se deplasează, reprezentat de vectorul mean shift, este orientat în direcția gradientului de densitate, iar densitatea în noul punct calculat are o valoare mai mare sau egală cu gradientul în punctul inițial.

Fie  $\mathbf{x}_i$  un vector ce aparține unui element din setul de date de dimensiune  $n$ ,  $z(\cdot)$  o funcție continuă unidimensională cu rol de netezire,  $\mathbf{H}$  o matrice lațime de bandă cu funcția de a scala componentele vectorului, iar  $d(\mathbf{x}, \mathbf{H})$  o măsură scalată a distanței în spațiul caracteristicilor. La imaginile monocrome, elementele ce compun setul de date sunt vectori formați din trei componente, două dintre acestea reprezentând coordonatele spațiale iar o componentă este valoarea din imagine sau informația de gamă. Pentru un pixel având coordonatele spațiale  $(a, b)$  și intensitatea  $f(a, b)$  vectorul devine:

$$\mathbf{x} = [a, b, f(a, b)]^T \quad (5.1)$$

Pașii algoritmului mean shift cu  $\mathbf{H}$  constant sunt:

1. inițializare  $\mathbf{y}_1 = \mathbf{x}$
2.  $j = 1$
3. Iterare (5.2),

$$\mathbf{y}_{j+1} = \frac{\sum_{i=1}^n \mathbf{x}_i z(\mathbf{y}_j - \mathbf{x}_i, H)}{\sum_{i=1}^n z(\mathbf{y}_j - \mathbf{x}_i, H)} \quad (5.2)$$

până la convergență, adică:

$$\|\mathbf{y}_{j+1} - \mathbf{y}_j\| < \varepsilon \quad (5.3)$$

unde  $\varepsilon$  este un anumit prag, iar  $j=1,2,\dots$ .

4. rezultatul este punctul de convergență  $\mathbf{y}_{j+1}$

Gradientul densității este zero în orice mod al densității, de aceea algoritmul mean shift se deplasează către un mod local unde se oprește. În timp ce algoritmul înaintază spre regiuni de densitate ridicată a spațiului, mărimea vectorului mean shift se reduce treptat, rezultând o convergență la un mod de densitate.


Mean shift poate fi derivat într-un model de estimare a funcției densitate de probabilitate sau într-un model de estimatori M [24]. În prima situație  $z(\cdot)$  este profilul kernelului, reprezentat de derivata kernelului de netezire utilizat pentru estimarea densității. În cel de-al doilea caz  $z(\cdot)$  este derivata funcției de pierdere. Ecuația principală a algoritmului calculează o medie ponderată a eșantioanelor de date. Numitorul ecuației are rolul de a normaliza la valoarea 1 suma ponderilor. Ponderile pentru fiecare eșantion depind de diferența normalizată între estimata curentă și eșantion. Funcția ponderilor este în așa fel definită astfel, cu cât diferența este mai mare cu atât este mai redusă ponderea non-negativă a eșantionului. Conform acestei proprietăți eșantioanele aberante au o pondere mai mică și prin urmare o influență redusă asupra estimatei.

La filtrarea imaginilor, mean shift este inițializat cu pixelul curent ca fiind prima estimată. Rezultatul este componenta de gamă a punctului de convergență a algoritmului. În timpul iterațiilor vectorul estimatei se modifică, prin urmare componenta spațială a estimatei la rândul ei se poate modifica, îndepărtându-se de locația inițială a pixelului și deplasându-se către locația cu densitatea maximă de pixeli similari. Această proprietate se poate utiliza în urmărirea (tracking) țintelor omogene pe un fundal în mișcare. În situația unei ținte heterogene, tracker-ul mean shift se poate defini să urmărească ținta prin determinarea locației ce minimizează disimilaritatea între histograma ținte și histograma locală [101]. În situația de față ținta este hipercogentică, având un grad destul de ridicat de omogenitate.

## 5.2. Utilizarea mean shift în tracking-ul leziunilor hepatice focale și extragerea curbelor intensitate-timp din CEUS

Problema critică întâmpinată în utilizarea algoritmului mean shift la urmărirea leziunilor hepatice focale în CEUS este aceea că spre deosebire de aplicațiile anterioare ținta nu doar se deplasează, dar în același timp aceasta

prezintă o variație continuă a intensității. Mai mult, ținta nu este deloc vizibilă în primele câteva zeci de cadre, pentru a elimina această a doua problemă se inițializează algoritmul prin selecția unui cadru adecvat, astfel încât ținta să fie vizibilă și în care este definită regiunea de interes ce conține leziunea focală hepatică. În figura 5.6 este ilustrată leziunea hepatică și RI selectată interactiv.



**Fig. 5.6** Selecție interactivă RI la cadrul 245 din secvența CEUS

Cea mai delicată problemă este abordată prin utilizarea unui parametru cu scară dinamică pentru componenta de gamă a datelor. Parametrul de scară pentru informația spațială este menținut constant deoarece dimensiunea țintei rămâne constantă.

Am propus o funcție pondere separabilă de forma:

$$z_k(a, b, f) = z(a)z(b)z_k(f) \quad (5.4)$$

unde,

$$z(a) = \begin{cases} 1 - \left| \frac{a}{h_{sa}} \right|, & \left| \frac{a}{h_{sa}} \right| < 1 \\ 0, & \text{altfel} \end{cases} \quad (5.5)$$

$$z(b) = \begin{cases} 1 - \left| \frac{b}{h_{sb}} \right|, & \left| \frac{b}{h_{sb}} \right| < 1 \\ 0, & \text{altfel} \end{cases} \quad (5.6)$$

$$z_k(f) = \begin{cases} 1 - \left| \frac{f}{h_r(k)} \right|, & \left| \frac{f}{h_r(k)} \right| < 1 \\ 0, & \text{altfel} \end{cases} \quad (5.7)$$

În ecuațiile (5.5) și (5.6),  $h_{sa}$  și respectiv  $h_{sb}$  sunt parametrii de scară spațiali. Algoritmul mean shift cu scară dinamică propus este prezentat mai jos. Fie  $f(a,b,k)$  intensitatea unui pixel la coordonatele spațiale  $(a,b)$  din cadrul  $k$ . Mai mult, fie  $\mathbf{K}$  numărul de cadre din studiu. Pașii algoritmului sunt:

1. Inițializarea estimatei mean shift a cadrului de start,  $k$ , astfel:

$$[a_1^k, b_1^k, f_1^k]^T = \begin{bmatrix} \text{mediana}(a \mid a \in RI) \\ \text{mediana}(b \mid b \in RI) \\ \text{mediana}(f(a,b,k) \mid (a,b) \in RI) \end{bmatrix} \quad (5.8)$$

Definim vecinătatea unui punct  $(a,b)$ ,  $N(a,b)$  ca o regiune rectangulară având dimensiunea RI centrată în  $(a,b)$ .

2. pentru  $i = k$  la  $\mathbf{K} - 1$ :

2.1.  $j = 1$

2.2. Iterează până la convergență,

$$[a_{j+1}^i, b_{j+1}^i, f_{j+1}^i]^T = \frac{\sum_{a,b \in N(a_j, b_j)} [a, b, f(a,b,i)]^T z(a-a_j)z(b-b_j)z_i(f(a,b,i) - f_j^i)}{\sum_{a,b \in N(a_j, b_j)} z(a-a_j)z(b-b_j)z_i(f(a,b,i) - f_j^i)} \quad (5.9)$$

unde  $j = 1, 2, \dots$

2.3. Se setează


$$[a_{conv}^i, b_{conv}^i, f_{conv}^i]^T = [a_{j+1}^i, b_{j+1}^i, f_{j+1}^i]^T \quad (5.10)$$

3. pentru  $i = k - 1$  la 0, efectuează pașii 2.1, 2.2, 2.3

Curba intensitate-timp generată este  $f_{conv}^k$ ,  $k = 1, 2, \dots, \mathbf{K} - 1$ . Parametrii de scară determină gradul de netezire a distribuției fiind cei care influențează cel mai mult rezultatele algoritmului. Rapiditatea cu care influența unui eșantion descrește pe măsură ce eșantionul se îndepartează de estimata curentă în spațiu sau în gamă este stabilită de scară. Se definesc parametrii de scară spațiali:

$$\begin{aligned} h_{sa} &= \frac{C}{2} \\ h_{sb} &= \frac{L}{2} \end{aligned} \quad (5.11)$$

unde C reprezintă numărul de coloane din RI, iar L reprezintă numărul de linii din RI selectată. Cu aceste valori, ponderile spațiale primesc valoarea unu la coordonatele spațiale ale estimatei mean shift curente și descreșc către zero în locațiile de graniță ale regiunii de interes centrate la coordonatele spațiale ale estimatei mean shift curente, rezultând un profil convex al kernelului, figura 5.7.



**Fig. 5.7** Model teoretic al profilului kernelului

Extragerea exactă a regiunii leziunii focale hepatice, este mai puțin importantă în generarea cu acuratețe a TIC având în vedere că pixelii localizați departe de centrul spațial curent al leziunii au o influență redusă asupra centrului spațial estimat următor, cât și asupra estimatei mean shift următoare.

Parametrul de scară pentru gamă este dificil de ales, deoarece intensitatea țintei prezintă o dinamică ridicată. Scara stabilește selectivitatea algoritmului de urmărire pentru informația de intensitate. Eșantioanele cu deviația intensității absolute în raport cu estimata curentă mai mare decât scara de gamă  $h_r$  au influența zero asupra următoarei estimate, conform cu kernelul aplicat. Scara nu trebuie să elimine eșantioanele cu o cantitate moderată de zgomot, acestea conținând informație utilă în estimarea cu acuratețe a intensității, însă o scară redusă rejectează cu precizie mai bună zgomotul. Scara de gamă decide maximul variației intensității intercadre pe care tracker-ul este capabil să o urmărească, prin urmare o scară foarte selectivă își pierde din eficiență.


O alta îngrijorare în selecția scării este pierderea graduală a contrastului în timp ce tracker-ul se întoarce de la cadrul selectat către cadrul inițial. În aceste cadre, pentru o scară de gamă înaltă, prea mulți pixeli din fundal sunt considerați în estimare. Tracker-ul poate fi ușor atras în fundal și ținta pierdută având în vedere contrastul scăzut și numărul ridicat de pixeli de fundal din vecinătatea leziunii. În astfel de situații, prima parte a curbei intensitate-timp generată coboară la zero foarte devreme, acest lucru ducând la afectarea drastică a parametrilor extrași din această curbă cum sunt, timpul de sosire (TA), timpul de creștere (TI) și timpul necesar pentru a se ajunge la maximă intensificare (TMI). Pentru a satisface toate cerințele menționate anterior, este propusă o selecție dinamică a scării de gamă:

$$h_r = \left( s_0 + \frac{k}{K} s_1 \right) f_k \quad (5.12)$$

unde  $s_0$  și  $s_1$  sunt două constante pentru minimumul și respectiv maximumul fracției de estimată utilizat la determinarea scării. Parametrul  $k$  introduce o dependență de timp și face ca scara de gamă să fie o fracție variabilă a intensității leziunii. Acest lucru permite obținerea unui tracker selectiv atunci când se deplasează dinspre cadrul selectat spre cadrele inițiale, unde leziunea focală hepatică este greu detectabilă de însăși cadrele medicale de specialitate.


### 5.3. Rezultate experimentale

În absența mișcării media și mediana intensităților oferă rezultate bune în generarea curbei, dar atunci când există o cantitate mare de mișcare a leziunii acuratețea acestor estimatori este puternic afectată. Figura 5.8 prezintă curba intensitate-timp pentru medie, iar în figura 5.9 este redată curba intensitate-timp pentru mediană. Acestea sunt generate cu un RI fix pentru o secvență video CEUS cu mișcare semnificativă a transductorului.




**Fig. 5.8** Generarea curbei intensitate-timp folosind mediile intensităților [46]






**Fig. 5.9** Generare curba intensitate-timp folosind medianele intensităților [46]


Efectele produse de mișcare sunt foarte bine percepute de aceste curbe. În cele două figuri 5.8 și 5.9 se poate observa că cele două grafice au variații mari după cadrul 280. Cea mai pronunțată mișcare a leziunii se manifestă începând de la cadrul 310 în continuare, după cum se poate observa din figurile 5.10-5.14. În figura 5.10 leziunea focală este amplasată într-o zonă central-dreapta a imaginii, ca apoi în figura 5.11 aceasta să apară deplasată în dreapta. Urmărind traiectoria leziunii în figurile 5.12, respectiv 5.13, observăm deplasarea acesteia în partea stângă a secvenței CEUS, pentru ca în figura 5.14 leziunea să fie localizată în partea dreaptă în urma parcurgerii întregului cadru.




**Fig. 5.10** Deplasarea leziunii hepatice în secvența video CEUS, cadrul 310




**Fig. 5.11** Deplasarea leziunii hepatice în secvența video CEUS, cadrul 328



**Fig. 5.12** Deplasarea leziunii hepatice în secvența video CEUS, cadrul 340




**Fig. 5.13** Deplasarea leziunii hepatice în secvența video CEUS, cadrul 350



**Fig. 5.14** Deplasarea leziunii hepatice în secvența video CEUS, cadrul 362

Curba intensitate-timp generată cu algoritmul mean shift este redată în figura 5.15.




**Fig. 5.15** Estimarea curbei intensitate-timp cu algoritmul mean shift [46]

Din figura 5.15 se poate observa că trackerul urmărește leziunea chiar și atunci când intensitatea acesteia scade și tot mai mulți pixeli din vecinătatea leziunii aparțin de fundal.

Variațiile semnificative datorate zgomotului speckle și mișcării, inserate de respirația pacientului și de mișcarea sondei ultrasonografice, sunt mult atenuate.

În figura 5.16 sunt marcate cu pixeli de culoare verde estimatele coordonatelor spațiale ale algoritmului de urmărire pentru a se observa compensarea mișcării realizată de tracker-ul mean shift.



**Fig. 5.16** Urmărirea leziunii hepatice cu tracker-ul mean shift [46]



## 6. CONCLUZII GENERALE ȘI CONTRIBUȚII

Teza de doctorat este dedicată unei probleme de mare interes din lumea medicală. Ea se referă așa după cum este menționat și în titlu la contribuții în diagnosticul asistat de calculator în imaginile de ultrasonografie abdominală. Am propus o nouă abordare în estimarea severității steatozei hepatice din informația conținută în imagini medicale ultrasonografice și extragerea curbei intensitate-timp din secvențe video folosind substanța de contrast (CEUS). Acestea sunt metode noi (prototipuri) de investigare în domeniu.

Realizarea obiectivelor propuse de noi implică studierea amănunțită a imaginilor și secvențelor video, precum și a posibilității de extragere și utilizare a informației specifice maladiilor hepatice. Cercetarea presupune studiul evaluării efectuate de medici specializați în gastroenterologie. Metodele propuse de noi iau în considerare cunoștințele medicale referitoare la diagnosticare. În ceea ce privește steatoza hepatică am propus o metodă de evaluare automată folosind calculatorul. Aceasta poate fi văzută ca un ajutor în prognoza medicală și automat în stabilirea unui diagnostic verosimil. În diagnosticarea leziunilor hepatice focale este utilizată substanța de contrast. Dinamica sanguină caracterizează leziunile hepatice, ca o consecință pe baza acesteia am extras curba de intensitate-timp folosind o metodă nouă.

### 6.1. Contribuții teoretice

1. Una din contribuțiile teoretice ale tezei este elaborarea și implementarea unei metode de clasificare automată a steatozei hepatice din imagini medicale ultrasonografice.

- a. Propunerea unui nou set inițial de caracteristici având în considerare cunoștințele medicale în diagnosticarea steatozei hepatice din imagini medicale ultrasonografice. Acesta este compus din: atenuarea posterioară maximă în RI hepatică, atenuarea posterioară minimă în RI hepatică, nivelul maxim robust în RI hepatică, nivelul minim robust în RI hepatică, mediana pentru niveluri de gri în RI hepatică, mediana pentru niveluri de gri dintr-un alt RI selectat cu rol de comparație în țesut lipsit de grăsimi ce aparține rinichiului.
- b. Propunerea unei metode de regresie robustă, pornind de la algoritmul RANSAC
- c. Pentru extragerea informației utile am considerat două regresii, pentru partea superioară și pentru partea inferioară a profilului de intensitate.
- d. Am analizat teoretic avantajele potențiale ale noii abordări, comparativ cu soluții de referință și identificând aplicații ce pot beneficia de aceste avantaje

- e. Comparație între două clasificatoare de tip Random Forests, unul ce utilizează întregul set de date și unul ce folosește dihotomii succesive

2. Am realizat un studiu comparativ între metoda de clasificare ce utilizează Random Forests și Support Vector Machine (SVM). Aceste două clasificatoare sunt cele mai performante în domeniul vederii artificiale. Studiul a fost efectuat pentru cazul de dihotomii succesive, atât pentru un set extins de caracteristici cât și pentru subseturi selectate.

3. Elaborarea și implementarea unei metode de extragere a curbei intensitate-timp, bazate pe algoritmul mean shift

- a. Propunerea algoritmului mean shift în extragerea curbei intensitate-timp din secvențe video CEUS. Acest algoritm poate fi folosit cu succes la obținerea parametrilor utilizați în sistemele de diagnostic medicală asistată de calculator.
- b. Curba intensitate-timp are un rol important în clasificarea automată a leziunilor hepatice focale observate în secvențe video CEUS. Estimarea acestei curbe cu acuratețe ridicată prezintă dificultăți semnificative. Pentru a obține o curbă intensitate-timp robustă vom folosi metoda neparametrică mean shift.
- c. Am propus un factor de scară variabil în vederea stabilirii unei selectivități variabile a tracker-ului cu privire la informația oferită de leziunea hepatică.

## 6.2. Contribuții aplicative

1. Implementarea unei metode robuste de extragere de caracteristici din imagini medicale ultrasonografice standard pe baza a două regresii.

2. Elaborarea și implementarea unei metode de clasificare automată a steatozei hepatice din imagini medicale ultrasonografice

- a. Adaptarea clasificatorului Random Forests pentru clasificarea steatozei din imagini ultrasonografice. Clasificare cu toate clasele de date și cu dihotomii succesive.

3. Elaborarea și implementarea unei metode de extragere a curbei intensitate-timp, bazate pe algoritmul mean shift.

- a. Am implementat o aplicație cu scop în extragerea mediei și medianei din regiunile de interes selectate pentru generarea curbei intensitate-timp.
- b. Implementare algoritmul mean shift pentru extragerea curbei intensitate-timp din secvențe video CEUS.
- c. Am definit factorul de scară variabil pentru a fi utilizat în cadrul algoritmului.

## BIBLIOGRAFIE

- [1] I. Sporea, A. Popescu, R. Şirli, „Why, who and how should perform liver biopsy in chronic liver diseases”, *World J. Gastroenterol.*, vol. 14(21), pp. 3396-3402, 7 June 2008
- [2] I. Sporea, R. Badea, A. Martie, R. Şirli, M. Socaciu, A. Popescu, M. Dănilă, „Contrast Enhanced Ultrasound for the characterization of focal liver lesions”, *Medical Ultrasonography*, vol. 13(1), no. 1, pp. 38-44, 2011
- [3] myMED.ro, On-line, <http://mymed.ro/ecografia-cu-substan-de-contrast-ceus.html>, accesat decembrie 2013
- [4] R. Lencioni, D. Cioni, C. Bartolozzi, „Tissue harmonic and contrast specific imaging: back to gray scale in ultrasound”, *Eur Radiol*, 2002; Vol. 12, pp. 151-165.
- [5] R. A. Marrona, R. D. Martin, V. J. Yohai, „Robust Statistics: Theory and Methods”, John Wiley & Sons, 2006
- [6] P. J. Rousseeuw, A. M. Leroy, „Robust Regression and Outlier Detection”, N. Y. Wiley, Ed., 1987
- [7] P. J. Rousseeuw, „Least median of squares regression”, *J. American Statistical Assoc.*, vol. 79, numar 388, pp. 871-880, 1984
- [8] F. R. Hampel, P. J. Rousseeuw, E. Ronchetti, W. A. Stahel, „Robust Statistics: The Approach Based on Influence Functions”, N. Y. John Wiley, Ed., 1986
- [9] P. J. Huber, „Robust Statistics”, N. John Wiley & Sons, Ed., 2004
- [10] D. R. Myatt, „Robust estimation in high noise and highly dimensional data sets with applications to machine vision”, Department of Cybernetics, October 2002
- [11] P. Meer, D. Mintz, D. Kim, and A. Rosenfeld, „Robust regression methods in computer vision: A review”, *International Journal of Computer Vision*, vol. 6, pp. 59-70, 1991
- [12] M. A. Fischler and R. C. Bolles, „Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography”, *Communications of the ACM*, vol. 24, pp. 381-395, 1981

- [13] I. Myung, „Tutorial on maximum likelihood estimation“, *Journal of Mathematical Psychology*, vol. 47, pp. 90-100, 2003
- [14] P. V. C. Hough, „Machine Analysis of Bubble Chamber Pictures“, *Proc. Int. Conf. High Energy Accelerators and Instrumentation*, 1959
- [15] P. H. S. Torr and A. Zisserman, „Robust computation and parametrization of multiple view relations“, *ICCV 1998*, pp. 727-732, 1998
- [16] P. H. S. Torr and A. Zisserman, „MLESAC: A new robust estimator with application to estimating image geometry“, *Computer Vision and Image Understanding*, vol. 78, pp. 138-156, 2000
- [17] P. H. S. Torr and D. W. Murray, „Outlier detection and motion segmentation“, in *Proc. Sensor Fusion VI*, Boston, 1993, pp. 432-443
- [18] D. R. Myatt, P. H. S. Torr, S. J. Nasuto, J. M. Bishop, and R. Craddock, „NAPSAC: High Noise, High Dimensional Robust Estimation – it’s in the Bag“, *Proc. British Machine Vision Conf.*, pp.458-467, 2002
- [19] B. Tordoff and D. Murray, „Guided sampling and consensus for motion estimation“, in *7th European Conference on Computer Vision*. vol. 1 Copenhagen, Denmark, pp. 82-96, May 2002
- [20] Myilsamy, Radha, and R. Muthukrishnan, „INAPSAC: A New Robust Inlier Identification Technique“, *Journal of Advanced Computer Science & Technology*, vol. 1.4, 2012, pp. 284-290.
- [21] J. Rabin, J. Delon, Y. Gousseau, L. Moisan, „MAC-RANSAC: a robust algorithm for the recognition of multiple objects“, *Fifth International Symposium on 3D Data Processing, Visualization and Transmission (3DPTV 2010)*, Paris, France, 2010
- [22] K. Fukunaga and L. D. Hostetler, „The estimation of the gradient of a density function with applications in pattern recognition“, *IEEE Trans. Information Theory*, vol. 21, pp. 32-40, 1975
- [23] D. Comaniciu and P. Meer, „Mean shift analysis and applications“, in *7th Proceedings IEEE International Conference on Computer Vision (ICCV’99)*, vol. 2, Kerkyra, Greece, 1999
- [24] D. Comaniciu and P. Meer, „Mean Shift: A robust approach toward feature space analysis“, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, pp. 603-619, 2002
- [25] G. C. Farrell, C. Z. Larter, „Nonalcoholic fatty liver disease: from steatosis to cirrhosis“, *Hepatology*, vol. 43.S1, pp. S99-S112, 2006
- [26] C. G. Lall, A. M. Aisen, N. Bansal, K. Sandrasegaran, „Nonalcoholic fatty liver disease“, *American Journal of Roentgenology*, vol. 190.4, pp. 993-1002, 2008

- [27] B. W. Smith, L. A. Adams. „Non-alcoholic fatty liver disease”, *Critical reviews in clinical laboratory sciences*, vol. 48.3, pp. 97-113, 2011
- [28] K. Doi, „Computer-aided diagnosis in medical imaging: historical review, current status and future potential”, *Computerized medical imaging and graphics*, vol. 31.4-5 pp. 198-211, 2007
- [29] K. Sugimoto, J. Shiraishi, F. Moriyasu, K. Doi, Computer-aided diagnosis for contrast-enhanced ultrasound in the liver, *World J Radiology* 2010 June 28, 2(6):215-223, doi:10.4329/wjr.v2.i6.215
- [30] A. Regev, et al., „Sampling error and intraobserver variation in liver biopsy in patients with chronic HCV infection”, *The American journal of gastroenterology*, vol. 97.10, pp. 2614-2618, 2002
- [31] S. H. Park, P. N. Kim, K. W. Kim, et al. „Macrovesicular Hepatic Steatosis in Living Liver Donors: Use of CT for Quantitative and Qualitative Assessment”, *Radiology*, vol. 239.1, pp. 105–112, 2006
- [32] A. E. Bohte, J. R. van Werven, S. Bipat, J. Stoker, „The diagnostic accuracy of US, CT, MRI and 1H-MRS for the evaluation of hepatic steatosis compared with liver biopsy: a meta-analysis”, *European radiology*, vol. 21.1, pp. 87-97, 2011
- [33] S. Strauss, E. Gavish, P. Gottlieb, L. Katsnelson, „Interobserver and intraobserver variability in the sonographic assessment of fatty liver.” *American Journal of Roentgenology*, vol. 189.6, W320-W323, 2007
- [34] G. Nagy, M. Gordan, A. Vlaicu, P. A. Mircea, D. Crisan and S. Valean, „Non-invasive evaluation of hepatic steatosis by ultrasound image analysis with simple brightness features and support vector machines”, *MediTech2007*, 27-29th September, Cluj-Napoca, 2007
- [35] G. Leandro, A. Mangia, J. Hui, P. Fabris, L. Rubbia-Brandt, G. Colloredo et al., „Relationship between steatosis, inflammation, and fibrosis in chronic hepatitis C: a meta-analysis of individual patient data.”, *Gastroenterology*, vol. 130.6, 1636-1642, 2006
- [36] G. T. Cao, P. F. Shi, B. Hu, „Liver fibrosis identification based on ultrasound images captured under varied imaging protocols”, *J Zhejiang Univ Sci B.*, Nov 6(11), pp. 1107-1114, 2005
- [37] M. Lupsor, R. Badea, C. Vicas, S. Nedevschi, H. Stefanescu et al., „Non-invasive Steatosis Assessment through the Computerized Processing of Ultrasound Images: Attenuation versus First Order Texture Parameters”, *International Conference on Advancements of Medicine and Health Care through Technology*, pp.184-189, 2011
- [38] A. Popescu, I. Sporea, V. Gui, D. Mihăilescu, R. Şirli, M. Dănilă, A. Jurchiş, M. Ardelean, O. Grădinaru, „Evaluarea Obiectivă Ecografică Asistată de Calculator a Steatozei Hepatice”, *A XV-a Conferinta Nationala a Societatii Romane de Ultrasonografie in Medicina si Biologie. Primul Simpozion de Educatie Medicala*

folosind Ultrasonografia, Universitatea de Medicina si Farmacie "Iuliu Hatieganu" Cluj-Napoca, 31.05-02.06 2012, Cluj-Napoca

[39] D. Mihăilescu, V. Gui, C. Toma, A. Popescu, I. Sporea, „Automatic Evaluation of Steatosis by Ultrasound Image Analysis”, 2012 IEEE 10th International Symposium on Electronics and Telecommunications Proceedings ISETC 2012, Timisoara, Romania, ISBN 978-1-4673-1174-8, IEEE Catalog Number CFP 1203L-PRT

[40] M. Lupsor, R. Badea, C. Vicas, S. Nedevschi, M. Grigorescu, C. Radu, H. Stefanescu, D. Crisan, „Non-invasive steatosis assessment in NASH through the computerized processing of ultrasound images: Attenuation versus textural parameters”, Proceedings of 2010 IEEE International Conference on Automation Quality and Testing Robotics (AQTR), vol. 2, 2010

[41] M. Webb, H. Yeshua, S. Zelber-Sagi, E. Santo, E. Brazowski, Z. Halpern, R. Oren, „Diagnostic value of a computerized hepatorenal index for sonographic quantification of liver steatosis”, American Journal of Roentgenology, vol. 192(4), pp. 909-914, 2009

[42] L. Breiman, „Random Forests”, Machine Learning, 2001, vol. 45, editia 1, pp. 5-32

[43] C. Vicas, S. Nedevschi, M. Lupsor, R. Badea, M. Grigorescu, „Steatohepatitis detection from ultrasound images using attenuation and backscattering coefficients” Journal of Automation, Computers, Applied Mathematics; vol. 16(3), pp. 20-26, 2007

[44] C. Cortes, V. Vapnik, „Support-Vector Networks”, Machine Learning, vol. 20, pp. 273-297, 1995

[45] D. Mihăilescu, V. Gui, C. Toma, A. Popescu, I. Sporea, „Computer Aided Diagnosis Method for Steatosis Rating in Ultrasound Images using Random Forests”, Med Ultrason, Vol. 15, Number 3, pages 184-190, 2013, ISSN 1844-4172

[46] D. Mihăilescu, V. Gui, C. Toma, A. Popescu, I. Sporea, „Simultaneous Filtering and Tracking of Focal Liver Lesion for Time Intensity Curve Analysis in Contrast Enhanced Ultrasound Imagery”, 2014 IEEE

[47] J. Shiraishi, K. Sugimoto, F. Moriyasu, N. Kamiyama, K. Doi, „Computer aided diagnosis for the classification of focal liver lesions by use of contrast enhanced-ultrasonography”, Med. Phys. 35(5), 1734-1746, 2008

[48] H. Trillaud, Jean-Michel Bruel, Pierre-Jean Valette, V. Vilgrain, G. Schmutz, R. Oyen, W. Jakubowski, J. Danes, V. Valek, C. Greis, „Characterization of focal liver lesions with SonoVue®-enhanced sonography: International multicenter-study in comparison to CT and MRI”, World J Gastroenterol, 15(30): 3748-3756, 2009

[49] K. Sugimoto, J. Shiraishi, F. Moriyasu, K. Doi, „Computer-aided diagnosis for contrast-enhanced ultrasound in the liver”, World J Radiol 28; 2(6) 215-223, 2010

- [50] C. F. Dietrich, G. Schuessler, J. Trojan, C. Fellbaum, A. Ignee, „Differentiation of focal nodular hyperplasia and hepatocellular adenoma by contrast-enhanced ultrasound.“, *British journal of radiology*, 78(932), 704-707, 2005
- [51] E. Leen, „The role of contrast-enhanced ultrasound in the characterisation of focal liver lesions.“, *European radiology*, 11, E27-E34, 2001
- [52] C. F. Dietrich, J. C. Mertens, B. Braden, G. Schuessler, M. Ott, A. Ignee, „Contrast-enhanced ultrasound of histologically proven liver hemangiomas“, *Hepatology*, 45(5), 1139-1145, 2007
- [53] A. Martegani<sup>19</sup>, et al. „Guidelines and Good Clinical Practice Recommendations for Contrast Enhanced Ultrasound (CEUS)–Update 2008.“, 2008
- [54] C. Huang-Wei, A. Bleuzen, M. Olar, D. Portalez, J. Roumy, H. Trillaud, F. Tranquart, „Role of Parametric Imaging in Contrast-Enhanced Sonography of Hepatic Focal Nodular Hyperplasia“, *J Clin Ultrasound* 34: 367–373, Issue 8, 2006
- [55] S. Lafitte, A. Higashiyama, H. Masugata, B. Peters, M. Strachan, O. L. Kwan, A. N. DeMaria, „Contrast Echocardiography Can Assess Risk Area and Infarct Size During Coronary Occlusion and Reperfusion: Experimental Validation“, *J Am Coll Cardiol.*, 39(9), pp. 1546-1554, 2002
- [56] F. Ma, Y. Cang, B. Zhao, Y. Liu, C. Wang, B. Liu, T. Wu, Y. Song, A. Peng, „Contrast-enhanced ultrasound with SonoVue could accurately assess the renal microvascular perfusion in diabetic kidney damage“, *Nephrol Dial Transplant.*, 27(7):2891-8, Jul. 2012
- [57] T. Fischer, M. Mühler, T. J. Kröncke, A. Lembcke, J. Rudolph, F. Diekmann, V. Ebeling, A. Thomas, C. Greis, B. Hamm, S. Filimonow, „Early postoperative ultrasound of kidney transplants: evaluation of contrast medium dynamics using time-intensity curves“, *Rofo.*, 176(4):472-7, Apr 2004
- [58] S. Aoki , R. Hattori , T. Yamamoto, Y. Funahashi, Y. Matsukawa, M. Gotoh, Y. Yamada, N. Honda, „Contrast-enhanced ultrasound using a time-intensity curve for the diagnosis of renal cell carcinoma“, *BJU Int.*, 108(3), pp. 349-54, 2011
- [59] J. S. Lee, „Digital image enhancement and noise filtering by use of local statistics“, *Pattern Analysis and Machine Intelligence*, IEEE Transactions on, vol. PAMI-2, pp. 165-168, 1980
- [60] J. S. Lee, „Speckle analysis and smoothing of synthetic aperture radar images“, *Computer graphics and image processing*, vol. 17.1, pp. 24-32, 1981
- [61] J. S. Lee, „Digital image smoothing and the sigma filter“, *Computer Vision, Graphics, and Image Processing*, vol. 24.2, pp. 255-269, 1983
- [62] L. Alparone, S. Baronti, A. Garzelli, „A hybrid sigma filter for unbiased and edge-preserving speckle reduction“, *Geoscience and Remote Sensing Symposium, IGARSS'95. Quantitative Remote Sensing for Science and Applications*, International (Vol. 2, pp. 1409-1411), IEEE, July 1995

- [63] H. Zhong, Y. Li, L. C. Jiao, „SAR image despeckling using bayesian nonlocal means filter with sigma preselection“, *Geoscience and Remote Sensing Letters, IEEE*, vol. 8.4, pp. 809-813, 2011
- [64] J. S. Lee, J. S. Lee, J. H. Wen, T. L. Ainsworth, K. S. Chen, A. J. Chen, „Improved sigma filter for speckle filtering of SAR imagery“, *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 47(1), pp. 202-213, 2009
- [65] V. S. Frost, J. A. Stiles, K. S. Shanmugam, J. C. Holtzman, S. A. Smith, „An adaptive filter for smoothing noisy radar images“, *Proceedings of the IEEE*, vol. 69(1), pp. 133-135, 1981
- [66] V. S. Frost, J. A. Stiles, K. S. Shanmugam, J. C. Holtzman, „A model for radar images and its application to adaptive digital filtering of multiplicative noise“, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. PAMI-4, pp. 157-166, 1982
- [67] D. T. Kuan, A. A. Sawchuk, T. C. Strand, P. Chavel, „Adaptive noise smoothing filter for images with signal-dependent noise“, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. PAMI-7, pp. 165-177, 1985
- [68] F. Qiu, J. Berglund, J. R. Jensen, P. Thakkar, D. Ren, „Speckle noise reduction in SAR imagery using a local adaptive median filter“, *GIScience & Remote Sensing*, vol. 41(3), pp. 244-266, 2004
- [69] J. S. Lee, „Speckle suppression and analysis for synthetic aperture radar images“, *Optical engineering*, vol. 25.5, 255636-255636, 1986
- [70] G. Sapiro, D. L. Ringach, „Anisotropic diffusion of multivalued images with applications to color filtering“, *Image Processing, IEEE Transactions on*, vol. 5.11, pp. 1582-1586, 1996
- [71] Y. Yu, S. T. Acton, „Speckle reducing anisotropic diffusion“, *Image Processing, IEEE Transactions on*, vol. 11.11, pp. 1260-1270, 2002
- [72] A. Achim, P. Tsakalides, A. Bezerianos, „SAR image denoising via Bayesian wavelet shrinkage based on heavy-tailed modeling“, *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 41(8), pp. 1773-1784, 2003
- [73] A. Achim, A. Bezerianos, P. Tsakalides, „Novel Bayesian multiscale method for speckle removal in medical ultrasound images“, *Medical Imaging, IEEE Transactions on*, vol. 20.8, pp. 772-783, 2001
- [74] A. Achim, A. Bezerianos, P. Tsakalides, „Ultrasound image denoising via maximum a posteriori estimation of wavelet coefficients“, *Engineering in Medicine and Biology Society, Proceedings of the 23rd Annual International Conference of the IEEE*, vol. 3, IEEE, 2001



- [75] A. Achim, A. Bezerianos, P. Tsakalides, „Wavelet-based ultrasound image denoising using an alpha-stable prior probability model”, *Image Processing, 2001. Proceedings. 2001 International Conference on*, vol. 2. IEEE, 2001
- [76] A. Isar, A. D. Isar, S. Moga, J. M. Augustin, X. Lurton, „Multi-scale MAP despeckling of sonar images”, *Oceans 2005-Europe*, vol. 2, pp. 1292-1297, IEEE, June 2005
- [77] A. Isar, D. Isar, A. Quinquis, „Multi-scale MAP Denoising of SAR and SAS images”, *Sea Technology*, 48(2), 46-48, 2007
- [78] I. Firoiu, C. Nafornta, J. M. Boucher, A. Isar, „Image denoising using a new implementation of the hyperanalytic wavelet transform”, *Instrumentation and Measurement, IEEE Transactions on*, vol. 58(8), pp. 2410-2416, 2009
- [79] C. Tomasi, R. Manduchi, „Bilateral Filtering for Gray and Color Images”, *Proceedings of the 1998 IEEE International Conference on Computer Vision*, pp. 839-946, Bombay, India, 1998
- [80] A. Buades, B. Coll, J. M. Morel, „A non-local algorithm for image denoising”, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005*, vol. 2, pp. 60-65, 2005
- [81] K. He, J. Sun, X. Tang, „Guided image filtering”, *Computer Vision–ECCV 2010*, Springer Berlin Heidelberg, pp. 1-14, 2010
- [82] V. Gui, „Edge Preserving Smoothing by Multiscale Mode Filtering”, *16th European Signal Processing Conference (EUSIPCO 2008)*, Lausanne, Switzerland, August 25-29, copyright by EURASIP, 2008
- [83] C. Ye, D. Tao, M. Song, D. W. Jacobs, M. Wu, „Sparse Norm Filtering”, *arXiv preprint arXiv:1305.3971*, 2013
- [84] P. Coupé, P. Hellier, C. Kervrann, C. Barillot, „Nonlocal means-based speckle filtering for ultrasound images”, *Image Processing, IEEE Transactions on*, vol. 18(10), pp. 2221-2229, 2009
- [85] S. K. Narayanan, R. S. D. Wahidabanu, „Despeckling of ultrasound imaging using median regularized coupled pde”, *ACEEE Int. J. on Control System and Instrumentation*, vol. 02, no. 2, June 2011
- [86] N. Azzabou, N. Paragios, „Spatio-temporal speckle reduction in ultrasound sequences”, *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2008*, Springer Berlin Heidelberg, pp. 951-958, 2008
- [87] S. Sudha, G. R. Suresh, R. Sukanesh, „Speckle noise reduction in ultrasound images by wavelet thresholding based on weighted variance”, *International Journal of Computer Theory and Engineering*, vol. 1.1, 1793-8201, April 2009

- [88] R. Vijayarajan, S. Muttan, „Cross Neighbourhood kernel filtering for speckle noise removal in ultrasound images”, *International Journal of Recent Technology and Engineering (IJRTE)*, vol. 1.2, June 2012
- [89] H. Lombaert, F. Cheriet, „Simultaneous image de-noising and registration using graph cuts: Application to corrupted medical images”, *Information Science, Signal Processing and their Applications (ISSPA)*, 11th International Conference on. IEEE, pp. 264-268, 2012
- [90] P. Frinking, L. Mercier, N. Rognin, M. Arditi, F. Tranquart, M. Schneider, „Real-time contrast-enhanced ultrasound parametric imaging in prostate”, *Proceedings of the 15th European Symposium on Ultrasound Contrast Imaging*, pp. 40–49, 2010
- [91] P. Angelelli, K. Nylund, O. H. Gilja, H. Hauser, „Interactive visual analysis of contrast-enhanced ultrasound data based on small neighborhood statistics”, *Computers & Graphics*, vol. 35(2), pp. 218-226, 2011
- [92] R. Prevost, B. Mory, J. Correas, L. D. Cohen, R. Ardon, „Kidney detection and real-time segmentation in 3D contrast-enhanced ultrasound images”, *2012 9th IEEE International Symposium on Biomedical Imaging (ISBI)*, pp. 1559-1562, May 2012
- [93] R. Shekhar, V. Zagrodsky, „Mutual information-based rigid and nonrigid registration of ultrasound volumes”, *IEEE Transactions on Medical Imaging*, vol. 21(1), pp. 9-22, 2002
- [94] M. Ledesma-Carbayo, J. Kybic, M. Desco, A. Santos, M. Suhling, P. Hunziker, M. Unser, „Spatiotemporal nonrigid registration for ultrasound cardiac motion estimation”, *IEEE Transactions on Medical Imaging*, vol. 24(9), pp. 1113-1126, 2005
- [95] M. J. Ledesma-Carbayo, J. Kybic, M. Desco, A. Santos, M. Unser, „Cardiac motion analysis from ultrasound sequences using non-rigid registration”, *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2001*, Springer Berlin Heidelberg, pp. 889-896, 2001
- [96] N. Rognin, R. Campos, J.-P. Thiran, T. Messenger, P. Broillet, P. Frinking, L. Mercier, M. Arditi, „A new approach for automatic motion compensation for improved estimation of perfusion quantification parameters in ultrasound imaging”, *The 8th French Conference on Acoustics, Tours (France)*, pp. 61-65, 2006
- [97] S. Schäfer, K. Nylund, O. H. Gilja, K. D. Tönnies, „Motion compensation of ultrasonic perfusion images”, In *SPIE Medical Imaging* (pp. 83200X-83200X). International Society for Optics and Photonics, February 2012
- [98] D. Comaniciu, P. Meer, „Robust analysis of feature spaces: color image segmentation”, *Computer Vision and Pattern Recognition, 1997. Proceedings.*, 1997 IEEE Computer Society Conference on. IEEE, pp. 750-755, 1997
- [99] D. Comaniciu, V. Ramesh, P. Meer, „Real-time tracking of non-rigid objects using mean shift”, *Computer Vision and Pattern Recognition, 2000. Proceedings.* IEEE Conference on, Vol. 2. IEEE, pp. 142-149, 2000

## 90 BIBLIOGRAFIE

---

- [100] G. R. Bradski, „Real time face and object tracking as a component of a perceptual user interface“, Applications of Computer Vision, 1998. WACV'98. Proceedings., Fourth IEEE Workshop on. IEEE, pp. 214-219, 1998
- [101] D. Comaniciu, V. Ramesh, P. Meer, „Kernel-based object tracking“, Pattern Analysis and Machine Intelligence, IEEE Transactions on, vol. 25.5, pp. 564-577, 2003